

UNIVERSIDADE FEDERAL DO CEARÁ
FACULDADE DE MEDICINA
DEPARTAMENTO DE CIRURGIA

AUXÍLIO AO DIAGNÓSTICO DE TUMORES DO ÂNGULO PONTO-CEREBELAR, COM A UTILIZAÇÃO DE TÉCNICAS DE INTELIGÊNCIA ARTIFICIAL

Francisco Flávio Leitão de Carvalho

FORTALEZA 2000

N.Cham. D 616.99281 C323a

Autor: Carvalho, Francisco Flávio L

Título: Auxilio ao diagnostico de tumor



1260103

Ac. 44358

BCS

C616121
R1260103
04/04/00

**UNIVERSIDADE FEDERAL DO CEARÁ
FACULDADE DE MEDICINA
DEPARTAMENTO DE CIRURGIA**

UFC	BIBLIOTECA UNIVERSITÁRIA
Nº. R1260103	
04 / 04 / 00	

**AUXÍLIO AO DIAGNÓSTICO DE TUMORES DO ÂNGULO PONTO-CEREBELAR,
COM A UTILIZAÇÃO DE TÉCNICAS DE INTELIGÊNCIA ARTIFICIAL**

FRANCISCO FLÁVIO LEITÃO DE CARVALHO

**FORTALEZA
2000**

**UNIVERSIDADE FEDERAL DO CEARÁ
BIBLIOTECA DE CIÊNCIAS DA SAÚDE**

D
616.99281
C323a
2000

**UNIVERSIDADE FEDERAL DO CEARÁ
FACULDADE DE MEDICINA
DEPARTAMENTO DE CIRURGIA**

**AUXÍLIO AO DIAGNÓSTICO DE TUMORES DO ÂNGULO PONTO-
CEREBELAR, COM A UTILIZAÇÃO DE TÉCNICAS DE INTELIGÊNCIA
ARTIFICIAL**

FRANCISCO FLÁVIO LEITÃO DE CARVALHO

Dissertação apresentada ao Programa de Pós-Graduação em Cirurgia do Departamento de Cirurgia da Faculdade de Medicina da Universidade Federal do Ceará para obtenção do título de Mestre em Cirurgia.

Área de Concentração: Bases da Técnica Cirúrgica e Cirurgia Experimental.

Orientador: Prof. Dr. Sebastião Diógenes Pinheiro

Fortaleza
2000

**UNIVERSIDADE FEDERAL DO CEARÁ
FACULDADE DE MEDICINA
DEPARTAMENTO DE CIRURGIA**

**AUXÍLIO AO DIAGNÓSTICO DE TUMORES DO ÂNGULO PONTO-
CEREBELAR, COM A UTILIZAÇÃO DE TÉCNICAS DE INTELIGÊNCIA
ARTIFICIAL**

FRANCISCO FLÁVIO LEITÃO DE CARVALHO

Dissertação apresentada ao Programa de Pós-Graduação em
Cirurgia do Departamento de Cirurgia da Faculdade de
Medicina da Universidade Federal do Ceará para obtenção do
título de Mestre em Cirurgia.

Área de Concentração: Bases da Técnica Cirúrgica e Cirurgia Experimental.

Orientador: Prof. Dr. Sebastião Diógenes Pinheiro

Fortaleza
2000

C 323 a Carvalho, Francisco Flávio Leitão de

Auxílio ao diagnóstico de tumores do ângulo ponto-cerebelar, com a utilização de técnicas de inteligência artificial / Francisco Flávio Leitão de Carvalho. – Fortaleza, 2000

87 f.

Orientador: Prof. Dr. Sebastião Diógenes Pinheiro

Dissertação (Mestrado). Universidade Federal do Ceará. Departamento de Cirurgia

1. Neoplasias cerebelares. 2. Inteligência artificial. I Título

CDD 616.99281

A meus pais Adamir e Prof. José Valdivino que conseguiram imprimir em mim parâmetros éticos.

in memoriam

À Marimilia, querida mulher nesses trinta e três anos de salutar convivência e de muita benevolência, compreensão e tolerância para com o meu trabalho médico.

A meus adorados filhos, Anamaria, Flávio, André e Manuela.

A meus caríssimos genros e noras, Francisco Eliezer, Daniele e José Wilson.

A meus netos Eliezer Filho e Flávia, que na pureza de criança me motivaram a consecução desta Dissertação.

Aos meus oito irmãos, com seus respectivos cônjuges.

cum amore

AGRADECIMENTOS

Ao **Prof. Dr. Sebastião Diógenes Pinheiro** que elegantemente cedeu seu precioso tempo e rico arquivo nosológico e prazerosamente aceitou ser o Orientador desta Dissertação.

Ao **Prof. Dr. Fernando Antonio de Carvalho Gomes** que me sugeriu o tema desta Dissertação e me orientou diuturna e incansavelmente, na realização da mesma.

Ao **Prof. Dr. Madjid Samii** que gentilmente cedeu parte de seu Banco de Dados sobre tumores do Ângulo Ponto-Cerebelar, sem os quais não teria sido possível a feitura desta Dissertação.

Ao **Dr. Flávio Leitão Filho**, meu estimado rebento, residente em Neurocirurgia no Serviço do Prof. M. Samii, que sacrificou inúmeras noites na análise do Banco de Dados.

Ao **Dr. Helder Tedeschi** pela orientação sobre a microneuroanatomia que ilustra a presente Dissertação.

À senhora **Norma de Carvalho Linhares**, Diretora da Biblioteca Central da Faculdade de Medicina da UFC, e à bibliotecária **Eliene Maria Vieira de Moura**, pela lhanza nas sugestões para correção dos aspectos bibliográficos desta Dissertação.

AGRADECIMENTOS

Ao **Prof. Dr. Sebastião Diógenes Pinheiro** que elegantemente cedeu seu precioso tempo e rico arquivo nosológico e prazerosamente aceitou ser o Orientador desta Dissertação.

Ao **Prof. Dr. Fernando Antonio de Carvalho Gomes** que me sugeriu o tema desta Dissertação e me orientou diuturna e incansavelmente, na realização da mesma.

Ao **Prof. Dr. Madjid Samii** que gentilmente cedeu parte de seu Banco de Dados sobre tumores do Ângulo Ponto-Cerebelar, sem os quais não teria sido possível a feitura desta Dissertação.

Ao **Dr. Flávio Leitão Filho**, meu estimado rebento, residente em Neurocirurgia no Serviço do Prof. M. Samii, que sacrificou inúmeras noites na análise do Banco de Dados.

Ao **Dr. Helder Tedeschi** pela orientação sobre a microneuroanatomia que ilustra a presente Dissertação.

À senhora **Norma de Carvalho Linhares**, Diretora da Biblioteca Central da Faculdade de Medicina da UFC, e à bibliotecária **Eliene Maria Vieira de Moura**, pela lhanza nas sugestões para correção dos aspectos bibliográficos desta Dissertação.

SUMÁRIO

1	INTRODUÇÃO.....	10
1.1	CARACTERIZAÇÃO DO APC.....	10
1.2	AFECÇÕES DO APC.....	12
1.2.1	Tumores.....	12
1.2.2	Doença Parasitária.....	13
1.2.3	Doença Vascular.....	13
1.2.4	Processos Infecciosos.....	14
1.3	INTRODUÇÃO À INTELIGENCIA ARTIFICIAL.....	15
1.3.1	IA Aplicada à Medicina.....	19
1.4	MOTIVAÇÃO.....	21
2	OBJETIVO.....	22
3	CASUÍSTICA E MÉTODO.....	23
3.1	O BANCO DE DADOS.....	26
3.2	MÉTODOS INDUTIVOS.....	29
4	RESULTADOS.....	47
4.1	MODELO DIAGNÓSTICO DE TAPC E DORL.....	47
5	DISCUSSÃO.....	51
6	CONCLUSÃO.....	60
7	REFERÊNCIAS.....	61
8	ANEXOS.....	67

RESUMO

Dados sobre os mais variados aspectos das mais diferentes afecções que acometem o ser humano estão se amontoando, em vertiginosa velocidade, em todos os países do mundo. A tecnologia moderna, que culmina com a democratização universal do conhecimento, permite transparente e relativamente fácil acesso a esses dados. Como expoente dessa tecnologia, cita-se a Internet, que popularizou o acesso à informações antes restritas a especialistas. Contudo, face ao proteiforme aspecto dos múltiplos sinais e sintomas das diversas doenças que acometem o Homem, a retirada de conhecimento estratégico desses Bancos de Dados é tarefa árdua, mesmo com o uso dos mais avançados computadores atualmente disponíveis. Graças contudo, a processos de Inteligência Artificial (IA) pode-se, mesmo usando-se computadores de baixa performance, adquirir-se conhecimento a partir desses dados o que já foi demonstrado em vários ramos do domínio médico. Esta Dissertação apresenta método de obtenção de modelo de auxílio ao diagnóstico dos tumores do Ângulo Ponto-Cerebelar (APC), utilizando-se técnica de IA. Obteve-se, a partir da casuística que alimentou o sistema, um modelo que apresenta boa acurácia (88,4%), onde permite-se uma certeza diagnóstica entre tumor do APC (TAPC) *versus* doenças otorrinolaringológicas (DORL), sem utilização de quaisquer métodos imagenológicos, nem procedimentos invasivos. A possibilidade de diferir-se entre TAPC e DORL, sem a utilização de caros e refinados exames complementares neuroradiológicos, poderá, por um lado, diminuir acentuadamente os custos para consecussão dos diagnósticos acima referidos. Por outro lado abreviará o tempo que um paciente geralmente leva para obter uma certeza diagnóstica entre TAPC e DORL. Além do mais, cria-se a possibilidade da formulação de normas para solicitação de Ressonância Nuclear Magnética e Tomografia Computadorizada em casos suspeitos da existência de TAPC, permitindo-se uma drenagem mais racional de pacientes de um centro menos desenvolvido para o que possua esses sofisticados métodos de exames complementares. Há, conseqüentemente, uma grande significação sócio-econômica nesse trabalho.

LISTA DE ABREVIATURAS

"AICA"	:artéria cerebelosa ântero-inferior
"PICA"	:artéria cerebelosa pósterio-inferior
APC	:ângulo ponto-cerebelar
CE	:cefaléia
CO	:perda dos sentidos, lipotímia
D5	:dor ou anestesia nos 2/3 anteriores da língua, dente ou córnea
D6	:diplopia
D8	:diminuição da audição
DD	:dificuldade de deglutição
DDORL	:diagnóstico de doença otorrinolaringológica
DF	:dor ou anestesia na face
DI	:disartria
DORL	:doença otorrinolaringológica
DTAPC	:diagnóstico de tumor do ângulo ponto-cerebelar
DV	:dor ou anestesia no 1/3 posterior da língua
EM	:ênese
EQ	:ataxia, vertigem, Romberg, Fournier
FN	:falso negativo
FP	:falso positivo
HDORL	:hipótese diagnóstica de DORL
HTAPC	:hipótese diagnóstica de TAPC
IA	:inteligência artificial
ID	:idade
IQ	:início da queixa
NI	:nistagmo
NN	:negativo
ORL	:otorrinolaringologia, otorrinolaringológico(a)
OU	:outros nervos
PA	:paresia
PP	:positivo
RDORL	:diagnóstico real de DORL
RNM	:ressonância nuclear magnética
RTAPC	:diagnóstico real de TAPC
S9	:sensibilidade gustativa (diminuição no 1/3 posterior)
SF	:sensibilidade gustativa (diminuição nos 2/3 anteriores)
SX	:sexo
TAPC	:tumor do ângulo ponto-cerebelar
TC	:tomografia computadorizada
TO	:tontura
Z8	:zumbido, acúfenos, tinnitus

LISTA DE FIGURAS

1. Régua do tempo dos principais eventos relacionados à IA	19
2. Visão geral do processo de descoberta do conhecimento.....	27
3. Comportamento típico da probabilidade de erro e a frequência de erro em função de k	35
4. Árvore de Decisão.....	38
5. Ilustração do processo de construção da árvore de decisão por CART.....	43
6. Árvore de decisão fornecida por CART para o modelo de discriminação TAPC, DORL. Rotulando cada ramo tem-se A=Ausência e P=Presença. PA representa paresia dos nervos facial e/ou glossofaríngeo, EQ é comprometimento do equilíbrio (Ataxia, Vertigem, Romberg e Fournier), DF é distúrbio de sensibilidade na face e TO representa tontura. Cada nó terminal é numerado 1-5.....	49
7. Relevância dos nós terminais representada na árvore da Figura 6.....	50
8. Relação entre dados, informação, conhecimento e a tomada de decisão estratégica, de acordo com o volume de armazenamento e o valor.....	54
9. Árvore de decisão fornecida por CART para o modelo de discriminação EPID x NEUR. Z8 representa zumbido, acúfenos e tinnitus, PA é a paresia dos nervos facial e/ou glossofaríngeo e DF é o comprometimento da sensibilidade da face. Rotulando cada ramo temos A=Ausência e P=Presença. Cada nó terminal é numerado 1-4.....	84
10. Relevância dos nós terminais na árvore representada na Figura 9.....	86

LISTA DE TABELAS

1. Variáveis e diagnósticos que representam um caso e sua representação no banco de dados.....	25
2. Matriz de frequências dos casos de teste (RTAPC,RDORL) versus diagnóstico do modelo (HTAPC,HDORL), onde PP representa os casos de tumores do APC diagnosticados corretamente pelo modelo, NN representa os casos de DORL corretamente diagnosticados pelo modelo, FN são os falsos negativos e FP os falsospositivos.....	48
3. Matriz de frequências obtida na avaliação da árvore de decisão da Figura 6	49
4. Matriz de frequências obtida na avaliação da árvore de decisão da Figura 9	85

1 INTRODUÇÃO

A presente Dissertação implica num trabalho retrospectivo multidisciplinar. Nela investiga-se a obtenção de um recurso auxiliar ao diagnóstico dos tumores localizados na fossa posterior, mais precisamente na região conhecida como do Ângulo Ponto-Cerebelar (APC), utilizando-se técnicas de aquisição de conhecimento extraído de Bancos de Dados, por processo de Inteligência Artificial (IA).

Contribui-se, assim, para a tomada de decisões no tratamento de pacientes portadores de processos expansivos no APC.

1.1 Caracterização do APC

Sabe-se que à medida que o conhecimento humano cresce exageradamente num determinado assunto, paralelamente cria-se uma terminologia que, se por um lado facilita a discussão inter pares, por outro lado dificulta o entendimento dos que conhecem pouco aquele assunto. Assim, impõe-se, para entendimento melhor das idéias que aqui serão apresentadas, que se teça algumas considerações fundamentais sobre o que é o APC e o que são técnicas de IA.

A região conhecida por APC, comportando também como vernáculo correto a denominação de *ângulo pontino-cerebelar* é, na maioria das vezes mal definida. DAVID (1961) descreve-a, simplesmente, como sendo o espaço compreendido entre a protuberância e o cerebelo. Anatomista nacional (MACHADO, 1974), simplesmente, identifica-a como a região entre a emergência do VII nervo craniano e

flóculo do cerebelo. Mesmo microanatomistas (GOULART, 1999) referem-se superficialmente ao APC. Um pouco mais próximo de uma descrição mais clara encontra-se MANTER (1960), que o define como “o espaço triangular, formado pelo bordo inferior dos pedúnculos cerebelares, pela parte contígua ao cerebelo e pela parte superior do bulbo”. Em excelente e recente compêndio de técnica neurocirúrgica LANG (1991) descreve o APC, sem o cuidado de localiza-lo dentro de limites precisos como região circundada pelas cisternas do cerebelo e pelo clivo e a face posterior do osso petroso, ventralmente. Inegavelmente, deve-se a RHOTON (1986) os melhores estudos microneuroanatomicos do APC. Descreve o mesmo o APC como a:

“região da fossa posterior, em forma de V, com seu ângulo agudo voltado para o lado e sua abertura voltada para a linha média, tendo como assoalho o pedúnculo cerebelar médio. Como limite superior tem-se a fissura cerebelo-pontina (braço superior) e, como limite inferior, o braço inferior da mesma fissura, bem como a fissura cerebelo-medular”.

Encontram-se nessa região: um tufo de plexo coroide exteriorizando-se pelo forame de Luschka, o flóculo que continuando-se com o vermis cerebelar constitui o lóbulo flóculo-nodular, os nervos facial e vestibulococlear (VII e VIII) próximos à porção término-lateral do sulco ponto-medular; o nervo trigêmeo (V), próximo ao limite superior do braço superior da fissura cerebelo-pontina; o nervo abducente (VI) paramedianamente situado no sulco ponto-medular; os nervos glosso-faríngeo, vago e acessório, (IX, X, XI) dispostos numa linha vertical posterior à oliva, a 2-3mm do nervo facial e o hipoglosso (XII) que nasce

anteriormente à oliva. Além de estruturas neurais a região do APC comporta ainda estruturas vasculares. Dentre as artérias encontram-se a cerebelosa superior, a cerebelosa ântero-inferior e a cerebelosa pósteroinferior. As duas últimas conhecidas, respectivamente pelas siglas americanas “AICA” e “PICA”. Já dentre as veias mais importantes encontram-se a petrosa superior ou veia de Dandy, a veia da fissura cerebelo-pontina, a veia da fissura cerebelo-medular e a veia do pedúnculo cerebelar médio (RHOTON, 1984).

1.2 Afecções do APC

1.2.1. Tumores

Na região acima descrita o neurinoma do acústico (ITO et al., 1977, KUO et al., 1997, MONSEL, et al., 1997, NOGUCHI et al., 1977, MATTHIES et al., 1997) e o meningioma (BAGULEY et al., 1997, WEISSMAN, 1997, ZEITUONI et al., 1997) são tumores por demais comuns nas casuísticas dos diversos serviços de todo o mundo. Entretanto, com menos freqüência, outros tumores assentam-se no APC, dentre os quais: o lipoma (BEHAR et al., 1998), o meduloblastoma (MEHTA & SHARR, 1998), o adenoma do saco endolinfático (FOLKER et al., 1997), o carcinoma de células basais (GALL et al., 1997), o cisto aracnoideo (JALLO et al., 1997), o epidermóide, o neurinoma do facial, o papiloma do plexo coroide, a metástase de neuroblastoma, o colesteatoma, o angioleiomioma, o hemangioma venoso, o angioma cavernoso (COMEY et al., 1997), a neurilemomatose (SHISHIBA, 1997), o glioma pontino (KOHAN, 1997), o neurinoma dos

nervos glossofaríngeo, vago e acessório (KRAUSS, 1997), o ependimoma (SANFORD et al., 1997), e o melanoma (SHINOAMI et al., 1996).

1.2.2 Doença Parasitária

Apesar da grande incidência de doenças parasitárias, principalmente da neuroschistosomose e da neurocisticercose, em nosso meio, não há relato, no Ceará de caso de neurocisticercose simulando tumor no APC. Contudo, além dos tumores acima citados, o cisto cisticercótico também pode comprometer o APC, simulando tumor. (DEL BRUTTO, 1997).

1.2.3 Doença Vascular

Artérias, normalmente encontradas no APC, como as artérias cerebelosa ântero-inferior e a cerebelosa pósterio-inferior, podem, apresentando-se com defeito na sua forma (dólicóartéria) ou no seu posicionamento anatômico, comprometerem nervos, determinando alterações patológicas. É o caso do tique espasmódico facial, bem como do tique doloroso (BEHAR et al., 1998). Assim, a presença de vasos anômalos, como no caso de alça vascular (HERZOG, 1997), simulando tumor do APC, embora raramente, é também afecção encontrada no APC.

1.2.4 Processos Infecciosos

Embora raramente encontrados no APC, os empiemas são complicações de infecções otológicas, especialmente o colesteatoma. Seu diagnóstico é frequentemente retardado, sendo algumas vezes confundido com processo meningítico, donde sua gravidade e prognóstico reservado. O fato é que processos infecciosos como o empiema (NATHOO et al., 1997) são descritos na literatura fazendo parte da coorte de doença que se localizam no APC.

Muito embora o neurinoma do acústico represente até 90% dos tumores do APC (KOHAN et al., 1997), os meningeomas 3 a 5% (ASAWAVICHIANGINDA, 1997), a existência de uma tão grande variedade de afecções nessa região, indiscutivelmente dificulta o diagnóstico. Apesar das exíguas dimensões da área do APC o grande número de estruturas tanto neurais como vasculares que podem ser comprometidas, dá origem a uma série de sinais e sintomas conhecidos como Síndrome do Ângulo Ponto-Cerebelar, (CAMBIER, 1988). Tal comprometimento, nos casos de tumores do APC, depende da rapidez de crescimento do tumor, de sua localização, de sua histologia, entre outros. Por outro lado, referidos sinais e sintomas não são patognomônicos de tumores do APC. Para dificultar o diagnóstico de uma lesão do APC sabe-se que uma paralisia do IX nervo craniano, tanto poderia ser decorrência da existência de processo expansivo no APC, como simplesmente um processo degenerativo (*e.g.* esclerose em placa) ou mesmo um processo tóxico-infeccioso agudo (*e.g.* difteria). Além do mais, como em muitos outros órgãos e sistemas da complexa anatomia humana, a certeza diagnóstica perseguida pelo médico, jamais é

alcançada, mormente quando da impossibilidade do uso de métodos auxiliares sofisticados e de alto custo (*e.g.* TC e RNM). Diz-se mesmo que a diferenciação diagnóstica entre tumor do APC e doença otológica é impossível, à base tão somente do exame clínico, sem a complementação de exames radiológicos. Finalmente para tornar mais difícil ainda o diagnóstico de tumores do APC, alguns sintomas associados aos mesmos são comuns à várias especialidades, de forma mais enfática à Neurologia, à Neurocirurgia e à Otorrinolaringologia (ORL).

1.3 Introdução à Inteligência Artificial

Assim como descreveu-se o APC, convém, igualmente, tecer-se alguns comentários sobre o que vem a ser IA, para que se possa entender, mais claramente porque foi escolhida para o presente estudo a IA na ajuda ao diagnóstico diferencial entre uma doença neurocirúrgica, qual seja o tumor situado no APC e doença otorrinolaringológica.

Uma demonstração inequívoca de que o bem maior do Homem é sua inteligência é que o mesmo se autodenominou, sem pejo, de “Homo Sapiens”.

Múltiplas são as definições atribuídas ao verbete “inteligência”. A riqueza da sinonímia¹ bem atesta a dificuldade de definir-se inteligência uma vez que a mesma envolve conceitos incompletamente compreendidos, tais como a criatividade, a curiosidade, o aprendizado, o

¹ O Dicionário da Língua Portuguesa Aurélio Burarque de Holanda define inteligência como: 1.Faculdade de aprender, de apreender ou compreender; percepção, apreensão, intelecto, intelectualidade.2. Qualidade ou capacidade de compreender e adaptar-se facilmente; capacidade, penetração, agudeza, perspicácia. 3. Maneira de entender ou interpretar, interpretação.4. Acordo, harmonia, entendimento recíproco. 5.Relações ou entendimentos secretos; conluio, maquinação, trama. 6. Destreza mental, habilidade.7. Capacidade de resolver situações problemáticas novas mediante reestruturação dos dados perceptivos. 8. Pessoa inteligente.

raciocínio, etc. Dificuldade idêntica tem-se para se definir Inteligência Artificial.

IA é um ramo do conhecimento humano que tenta criar “entidades inteligentes”. Sob certos aspectos assemelha-se à Filosofia e à Psicologia que se interessam pelo processo do pensamento, do raciocínio e da inteligência. A IA além destes aspectos, luta tenazmente pela criação de “entidades inteligentes”. Pode-se dizer que seu nascimento se deu oficialmente, como resultado de um seminário de dois meses de duração coordenado por McCarty, com a colaboração de Minsky, Shannon, Rochester, em Dartmouth, em 1956, quando o termo foi criado. Por isso atribui-se a John McCarty o epíteto de o pai da IA (HONAVAR & UHR, 1994).

Desnecessário se faz dizer que não fora a pesquisa desenvolvida, independentemente, por três nações durante a segunda grande guerra mundial o computador não teria surgido e, como consequencia, não poderia existir o que se entende hoje como IA. Em 1940, Alan Turing e seu grupo criam o primeiro computador que recebeu o nome de Heath Robinson, homenagem a famoso cartunista da época, criador de máquinas extravagantes. A finalidade da construção desse computador foi traduzir mensagens codificadas do exército alemão. À medida que os alemães dificultavam seus códigos surgia a necessidade de computador mais preciso, sendo a segunda linhagem desse artefato o Colossus. Concomitantemente, Konrad Zuse, na Alemanha, com apoio do III Reich, criou o Z-3 e logo a seguir o Plankalkul. Paralelamente os EE.UU., iniciaram-se, timidamente no mundo da computação, lançando o ABC, como fruto do estudo de John Atanasoff e Clifford Berey da

Universidade de Iowa. Desenvolveram em seguida uma indústria que movimentava bilhões de dólares e que gera atualmente, 10% do seu PIB, sendo seu principal representante a IBM. Não seria justo se fosse omitido como precursor do computador o ábaco, ou o nome de Blaise Pascal, que na metade do século XII, criou uma máquina capaz de somar e subtrair – a famosa *Pascaline*. Leibnitz (1694) criou uma máquina multiplicadora e teria o sonho de idealizar “uma álgebra universal, através da qual, todo conhecimento, incluindo as verdades morais e metafísicas, pudessem, algum dia, serem trazidas para dentro de um sistema dedutivo único”.

Prova da dificuldade em se apresentar um enunciado exato e completo sobre IA são as múltiplas definições que RUSSEL E NORVIG (1995), oferecem, compulsando oito livros de texto considerados os melhores sobre IA, publicados nas últimas décadas:

- ◆ “O novo e excitante esforço para fazer computadores pensar... máquinas com mente, no sentido estrito e amplo” (HAUGELAND, 1985);
- ◆ “A automação de atividades associadas à inteligência humana, tais como: decidir, resolver problemas, aprender” (BELLMAN, 1978);
- ◆ “O estudo das faculdades mentais através do uso de modelos computacionais “ (CHARNIAK & MCDERMOTT, 1985);
- ◆ “O estudo do comportamento que torna possível perceber, raciocinar e agir” (WINSTON, 1992);

- ♦ “A arte de criar máquinas que realizam funções que requerem inteligência quando realizadas por humanos” (KURZWEIL, 1990);
- ♦ “O estudo de como fazer os computadores realizarem coisas que até o presente momento, os humanos fazem melhor” (RICH KNIGHT, 1991);
- ♦ “O campo de estudo que procura explicar e estimular comportamento inteligente em termos de processo computacional”. (SCHALKOFF, 1991);
- ♦ “O ramo da ciência computacional que está preocupada com a automação do comportamento inteligente” (LUGER e STUBBLEFIELD, 1993).

Enfatizando-se os aspectos históricos da IA, SIMON (1957), citado por RUSSEL E NORVIG (1995), em congresso sobre ciência da computação, declara: “que agora no mundo há máquinas que pensam, que aprendem e que criam. Mais do que isso, sua habilidade em fazer essas coisas está aumentando rapidamente, até que num futuro próximo o espectro de problemas que elas podem resolver serão co-existentes com o espectro para o qual a mente humana se aplica” (RUSSEL & NORVIG, 1995).

A Figura 1 ilustra os principais eventos relacionados à IA.

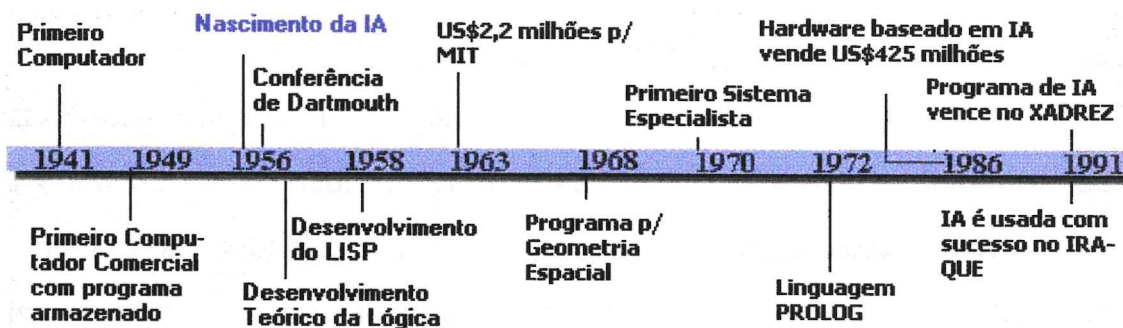


Figura 1. Régua do tempo dos principais eventos relacionados à IA.

1.3.1 IA Aplicada à Medicina

As informações sobre afecções de um modo geral, avolumam-se nos bancos de dados dos hospitais do mundo inteiro. Sabe-se que a análise desses dados encontra-se dificultada por vários fatores, dentre os quais a inexistência de uma linguagem internacional única para descrevê-los. A esse aspecto junta-se o fato de referidos dados pecarem por: a) serem incompletos (ausência de alguns parâmetros necessários à formulação do diagnóstico); b) serem incorretos (avaliação incorreta ou subjetiva por parte do profissional responsável pelo exame do paciente); c) em alguns casos, serem esparsos (pequeno número de casos ou prontuários com anotações pobres), d) em alguns casos serem redundantes (a fase de seleção dos casos pode introduzir registros duplicados). Pelos fatos acima expostos, métodos computacionais vem sendo desenvolvidos para minorar essas deficiências (LAVRAC, 1999). O uso de sistemas computacionais em medicina vem sendo verificado há muito. Por exemplo, em Neurocirurgia cita-se a tomografia computadorizada e, mais recentemente a neuronavegação (MEYER et al., 1998).

Desde os primeiros dias da ciência da computação muitos paradigmas computacionais surgiram para o estudo da IA. Os problemas de interesse da IA são, em geral, ligados à características inerentes ao homem. Por exemplo, ver e reconhecer formas, o processamento da linguagem natural, o raciocínio, o aprendizado automático, a robótica, etc (BENABID et al., 1998; RABISCHONG, 1998). Todas essas características são, em termos computacionais, muito difíceis. Isso significa que os computadores atuais, mesmo os supercomputadores, não conseguiriam dar uma resposta precisa dentro de um tempo aceitável, *i.e.* a proibitiva complexidade da entrada de dados geraria um processamento por anos, ou até por séculos. Por isso, para resolvê-los, necessita-se de métodos especiais que conseguem evitar a complexidade dos problemas e encontrar uma resposta aproximada dentro de um tempo aceitável, usando-se os computadores disponíveis atualmente. Portanto, esses métodos computacionais de IA fazem com que as falhas supracitadas na descrição dos dados, não se constituam empecilho à aplicação da IA. O mesmo não se pode dizer dos métodos estatísticos paramétricos, correntemente usados em análise de dados.

Métodos de IA vêm sendo usados em vários ramos da atividade médica, notadamente através do uso de sistemas especialistas dedutivos e da indução de modelos de conhecimento a partir de casos, dentre outros. Para evidenciar o uso disseminado desses métodos em medicina, cita-se a sua aplicação na área cardíaca (KOMOROWSKI & OHRN, 1999), em Imunologia (LATHROP et al., 1999), em Oncologia (FOLGEL et al., 1998), em Neuroanatomia (GIBAUD et al., 1998), em reprodução humana (JURISICA et al., 1998), em Reumatologia (ZUPAN & DZEROSKI, 1998), em Neurologia (TOFFANO-NIOCHE et al., 1998), em

Traumatologia (INNOCENT et al., 1997) e em Oftalmologia (POGGIO & BEYMDWE, 1996), entre outras.

1.4 Motivação

Os fatores desencadeantes desse Estudo foram:

1. a idéia de se conseguir indicação mais racional para solicitação de exames neuroradiológicos em caso de dúvida entre TAPC E DORL;
2. a possibilidade de se obter encaminhamento mais lógico de pacientes residentes em áreas desprovidas de aparelhagem neuroradiológica sofisticada para centros melhor aparelhados;
3. a importância de se estimular o relacionamento interdisciplinar entre área médica e área da ciência da computação;
4. finalmente, a necessidade de despertar o interesse do médico, de um modo geral, em manter programa de coleta de dados, de onde se possa, no momento adequado, extrair-se conhecimento.

2 OBJETIVO

Nessa Dissertação, serão usadas técnicas computacionais para prover elementos de auxílio ao diagnóstico de tumores do APC. O objetivo do trabalho aqui apresentado é a **obtenção de modelo de diagnóstico que seja capaz de diferenciar entre casos de tumores do APC (TAPC) e casos de doenças otorrinolaringológicas (DORL), sem a utilização de exames complementares, mas somente às custas de dados obtidos da história clínica.**

3 CASUÍSTICA E MÉTODO

Os dados usados nesse trabalho advêm de três fontes: do serviço do Prof. Madjid Samii em Hannover, Alemanha; do Instituto de Neurocirurgia de Fortaleza (INF) e da Clínica do Prof. Sebastião Diógenes Pinheiro, perfazendo um total de 750 casos. Desse total, 275 casos dizem respeito a TAPC (236 de Hannover e 39 do INF) e 475 casos representam relatos de DORL. A coleta dos dados foi efetuada como a seguir exposto:

1. Os dados oriundos de Hannover foram coletados entre os pacientes atendidos nos anos de 1993 a 1996, selecionando-se os casos de neurinoma do acústico, meningioma e epidermóide, tendo sido descartados tumores outros que incidiam debilmente naquela casuística . Ressalte-se que referido Serviço é de referência não somente para a Europa, como para todo o mundo, de um modo geral.
2. Os dados do INF dizem respeito a casos de neurinoma do acústico e foram coletados entre os anos de 1993 e 1999, após terem sido descartados os casos sem comprovação histopatológica.
3. Finalmente, os dados advindos da Clínica de ORL do Prof. Diógenes foram coletados entre 1985 e 1999. Foram selecionados apenas os casos que apresentavam otoscopia normal e tinham um ou mais dos seguintes sinais e sintomas encontrados em tumores do APC: zumbido, acúfeno, tinitus, alteração da audição (hipoacusia ou anacusia), comprometimento do equilíbrio e vômitos. Impõe-se dizer

que todos os casos com hipoacusia de condução e/ou mista foram descartados. Todos os pacientes selecionados com testes supraliminares e de discriminação vocal que apresentavam baixa discriminação vocal desproporcional à audiometria tonal foram encaminhados para estudo imaginológico. O estudo radiológico obedeceu à seguinte sequência: iodomeatocisternografia, tomografia computadorizada e finalmente ressonância nuclear magnética.

Trata-se assim de um estudo retrospectivo. A planilha que apresenta todos os casos, encontra-se no Anexo A. A idade média dos pacientes é de 50,49 anos, com mínima de 5 e máxima de 90 anos. Os pacientes do sexo masculino perfazem 299, enquanto que os do sexo feminino totalizam 447. Em 4 casos o sexo não foi registrado.

A Tabela 1 apresenta as variáveis (sinais, sintomas, sexo, idade e início da queixa) e diagnósticos que descrevem a casuística. A coluna à esquerda relaciona as variáveis com os seus respectivos valores e a coluna à direita indica as siglas e códigos usados como entrada no banco de dados. As variáveis que podem assumir os valores "presença" ou "ausência", foram coletadas da seguinte forma: no prontuário do paciente, quando confirma-se a presença de certo sinal ou sintoma, este terá valor "presença", em contrapartida, a não citação indica o valor "ausência". Vale ressaltar que nenhuma das variáveis descritas exige o resultado de exames complementares invasivos ou não.

Tabela 1. Variáveis e diagnósticos que representam um caso e sua representação no banco de dados

VARIÁVEIS	Representação
1. Idade [em anos]	ID [anos]
2. Sexo [Feminino,Masculino]	SX[F,M]
3. Início da Queixa [em meses]	IQ[meses]
4. Zumbido, Acúfenus, Tinitus [Presença, Ausência]	Z8[P,A]
5. Perda dos sentidos, lipotímia [Presença, Ausência]	PS[P,A]
6. Dor ou anestesia nos 2/3 anteriores da língua, dente ou córnea [Presença, Ausência]	D5[P,A]
7. Dor ou anestesia no 1/3 posterior da língua [Presença, Ausência]	DV[P,A]
8. Dor ou anestesia na face [Presença, Ausência]	DF[P,A]
9. Diminuição da audição(hipoacusia, anacusia) [Presença, Ausência]	D8[P,A]
10. Dificuldade de Deglutição [Presença, Ausência]	DD[P,A]
11. Êmese [Presença, Ausência]	EM[P,A]
12. Ataxia, Vertigem, Romberg, Fournier [Presença, Ausência]	EQ[P,A]
13. Cefaléia [Presença, Ausência]	CE[P,A]
14. Diplopia [Presença, Ausência]	D6[P,A]
15. Paresia [Presença, Ausência]	PA[P,A]
16. Tontura [Presença, Ausência]	TO[P,A]
17. Sensibilidade gustativa diminuição nos 2/3 anteriores [Presença, Ausência]	SF[P,A]
18. Sensibilidade gustativa diminuição no 1/3 posterior [Presença, Ausência]	S9[P,A]
19. Disartria [Presença, Ausência]	DI[P,A]
20. Nistagmo [Presença, Ausência]	NI[P,A]
21. Outros nervos [Presença, Ausência]	OU[P,A]
22. DIAGNÓSTICO (ou classe)	D[(TAPC,DORL)]

3.1 O Banco de Dados

Foram consideradas vinte e uma variáveis, mais o diagnóstico. Todas tiveram como valor “Presença ou Ausência”, com exceção das variáveis relacionadas à idade, ao sexo e ao início da queixa principal. Com referência à variável idade, foram desprezados os meses, sendo considerado apenas o número de anos de cada paciente. Quanto ao tempo de início da queixa principal foi o mesmo anotado em meses. Nos três bancos de dados utilizados nessa Dissertação falta, algumas vezes, clareza com respeito ao exato significado de algumas variáveis. Assim as variáveis zumbido (sensação semelhante ao ruído de asas de um inseto), acúfeno (alucinação auditiva) e tinnitus (sensação de ruído por lesão do ouvido interno, por exemplo) foram consideradas como sendo a mesma variável que foi codificada como Z8. As variáveis “Perda dos Sentidos” e “Lipotímia” que têm nuances diagnósticas diferentes, vez que por perda dos sentidos entende-se o desaparecimento total da consciência, enquanto que por “Lipotímia” entende-se um mal estar, com certo grau de obnubilação mental, também foram consideradas como semelhantes, tendo sido codificadas com a sigla “PS”.

Sempre que possível, para facilitar o entendimento da representação dos sinais e sintomas (variáveis), criou-se sigla que tivesse alguma relação com as mesmas. Por exemplo: a variável diminuição da audição ficou representada pela sigla D8, onde D significa diminuição e 8 corresponde ao oitavo nervo craniano – o vestibulo-coclear.

Por vezes a sigla representativa da variável foge à esta norma, como por exemplo, a sigla diplopia representada como D6. Não se quer com o número 6 restringir-se o aparecimento de diplopia exclusivamente ao comprometimento do sexto nervo craniano.

É importante que se entenda como PA, exclusivamente a paresia dos nervos facial ou glossofaríngeo, nunca podendo ser portanto, confundida com a paresia de membros.

Sobre o diagnóstico, os valores TAPC e DORL significam respectivamente tumor do ângulo ponto-cerebelar e doença otorrinolaringológica.

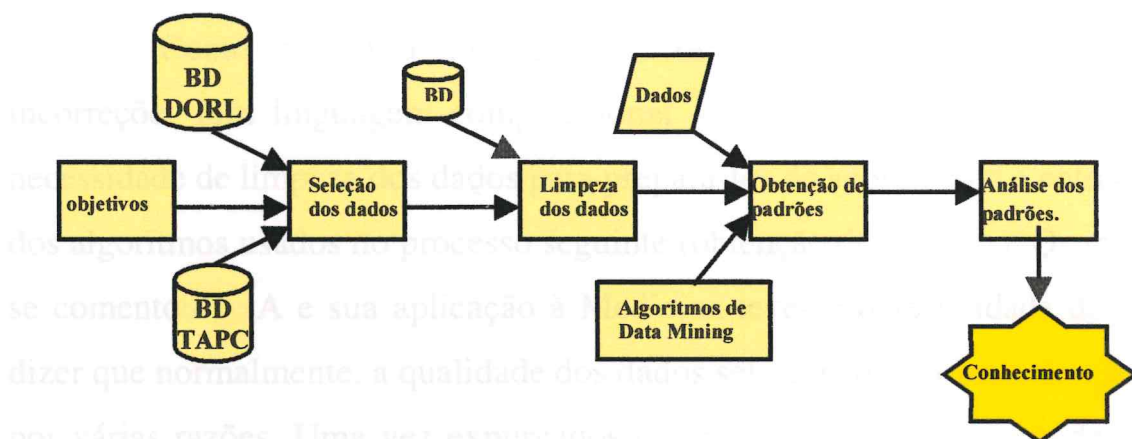


Figura 2. Visão geral do processo de descoberta do conhecimento. BD sendo a sigla para Banco de Dados.

A Figura 2 fornece uma visão geral do processo de aquisição de conhecimento a partir de dados como os há pouco descritos. Inicialmente, deve-se estabelecer os objetivos da busca por conhecimento nos dados. Para alcançar o objetivo proposto, parte-se de casos neurocirúrgicos previamente diagnosticados, do ponto de vista clínico e **confirmados através de exames neuroradiológicos, pelos achados cirúrgicos e histopatológicos**, assim como de casos da clínica de ORL, com as características já descritas. É bem verdade que existem ocasiões onde não são preestabelecidos os objetivos. Nesses casos deve-se efetuar uma

exploração do banco de dados na busca de similaridades e, em seguida, estabelecer objetivos ou atributos-alvo.

Uma vez definidos os objetivos, deve-se selecionar quais são os registros relevantes ao processo. Na presente Dissertação dispõe-se de três bases de dados e deseja-se obter todos os registros que se relacionem com TAPC e DORL. Ferramentas de amostragem estatística de regressão linear e correlação são muito úteis nessa fase. Deve-se ter em mente que quanto maior for a amostra mais precisos serão os resultados.

Como foi dito inicialmente, os dados podem apresentar incorreções (em linguagem computacional – “ruídos”), razão porque da necessidade de limpeza dos dados para prepará-los de acordo com a entrada dos algoritmos usados no processo seguinte (obtenção de padrões). Quando se comentou a IA e sua aplicação à Medicina teve-se oportunidade de se dizer que normalmente, a qualidade dos dados selecionados deixa a desejar, por várias razões. Uma vez expurgados os erros acima descritos, pode-se separar uma parte dos dados para análise posterior dos padrões obtidos. Esta parte de dados chama-se de **conjunto de teste**.

A fase de obtenção de padrões será abordada em detalhes nas próximas seções.

Na análise dos padrões obtidos tem-se uma hipótese relacionada aos dados de entrada e deve-se testar essa hipótese. A primeira providência é a de se obter uma avaliação dos resultados através do conjunto de teste independente dos dados usados na geração dos padrões. Nem sempre é possível a separação de um conjunto de teste, nesse caso, usa-se técnicas de validação cruzada (BREIMAN *et al.*, 1983) para estimar a qualidade dos resultados.

O conjunto de técnicas utilizadas no processo de aquisição de conhecimento é inerente aos algoritmos indutivos de aprendizagem, que a seguir descreve-se detalhadamente.

3.2 Métodos Indutivos

O termo “Aprendizagem Indutiva” (ou “*Inductive Learning*”) foi introduzido na área de Inteligência Artificial no fim dos anos 80. No entanto o objetivo desses métodos não era novo, pois na área de estatística no fim dos anos 70, alguns métodos indutivos já haviam sido propostos. Nesse capítulo apresenta-se a aprendizagem indutiva de procedimentos (ou modelos) de classificação (ou discriminação) a partir de exemplos. Os algoritmos aqui apresentados são aproximativos (heurísticos), uma vez que o problema é considerado NP-difícil (vide Capítulo 5). O problema que será abordado relaciona-se à análise discriminante, ao reconhecimento de formas, ao diagnóstico médico, etc. Vale ressaltar o caractere simbólico (discreto) da representação dos dados e que a busca tem por objetivo encontrar procedimentos de discriminação expressos em linguagem simbólica e convivial. Deve-se também atentar para o interesse pelos aspectos algorítmicos do problema.

Fundamentos

Como foi dito acima, o objetivo do presente Estudo é o de “aprender procedimentos de discriminação a partir de exemplos”. Dar-se-á agora a definição de cada uma dessas palavras. A linguagem humana sendo muito subjetiva, deixando margem a interpretações diferentes para um mesmo verbete, não poderia servir para definir os conceitos básicos de

aprendizagem automática. Daí a utilização de uma linguagem matemática simples, como a que a seguir será empregada.

Um **exemplo** (aqui, sinônimo de caso) é um par (x,c) onde x representa a descrição de um caso, de um indivíduo, etc., e c representa uma classe (ou diagnóstico). Os casos são descritos por um conjunto de atributos (ou sinais, sintomas, idade, etc), representado por $V_p = \{x_1, x_2, \dots, x_p\}$, onde cada um dos x_i tem seus valores num domínio D_i , podendo ser assimilado a $\{\text{Positivo, Negativo}\}$, $\{0,1\}$, $\{\text{severo, moderado, fraco}\}$, etc. *In casu*, para descrever um quadro clínico, foi usado o domínio $\{P, A\}$ (Presença ou Ausência) para cada sinal ou sintoma (vide Tabela 1).

A **classe** (aqui, sinônimo de diagnóstico) do exemplo poderá ser representada por um inteiro $c \in \{1,2, \dots, C\}$, onde C designa o número de classes. A classe exprime um diagnóstico médico, a presença ou ausência de uma certa propriedade do objeto, etc. Quando existem apenas duas classes, como na presente Dissertação, diz-se que o exemplo é positivo ou negativo, de acordo com a classe, *i.e.* quando se tratar de TAPC diz-se que o exemplo (ou caso) é positivo, caso contrário, um exemplo com a classe DORL, será negativo.

Um **exemplo binário** é um exemplo descrito unicamente por atributos binários e cuja classe é uma variável binária. Seja $V_p = \{x_1, x_2, \dots, x_p\}$ um conjunto de atributos binários, $L_p = \{x_1, \bar{x}_1, \dots, x_p, \bar{x}_p\}$ é o conjunto de literais de V_p ². Nessa Dissertação, os exemplos são binários.

De um ponto de vista probabilístico, um exemplo (x,c) é a realização de uma variável aleatória (X,C) com valores em

$$D_1 \times D_2 \times \dots \times D_p \times \{1,2,\dots,C\},$$

² \bar{x}_1 representa a negação de x_1

Onde p representa a dimensão dos exemplos. Em “data mining”, considera-se que não são conhecidas nem a regra de decisão $P(C|X)$, nem as propriedades do ambiente $P(X)$, nem mesmo a lei subjacente à distribuição $P(X,C)$. Para exprimir essa última restrição, localiza-se num contexto não paramétrico, ou “*distribution-free*”.

Uma **amostra** é um conjunto finito de exemplos obtidos de maneira independente, seguindo a distribuição $P(X,C)$. No curso deste trabalho, fala-se frequentemente de conjunto de aprendizagem ou de conjunto de teste. Trata-se de amostra de exemplos, como foi acima definido. O Anexo A apresenta a amostra de exemplos usada nesta Dissertação.

Um **procedimento de classificação** (ou modelo) é uma aplicação F definida sobre X (descrição dos casos) e com valores em $\{1,2,...,C\}$ (diagnósticos). O objetivo da aprendizagem é descobrir o procedimento de classificação que governa os exemplos. De uma maneira ou de outra, os métodos de aprendizagem indutiva efetuam sempre uma exploração de um espaço previamente fixado de procedimentos de classificação viáveis. Esse espaço será representado por F . No caso dos exemplos binários, considerar-se-á que F é um conjunto de fórmulas lógicas, de forma predeterminada, expressas com ajuda dos operadores booleanos usuais: \wedge (e), \vee (ou), \neg (negação).

Aprender indutivamente, é ao mesmo tempo um processo de cálculo e uma exigência de capacidade preditiva, com respeito ao procedimento de classificação encontrado. O processo pode se resumir, como a seguir: dispõe-se de um conjunto de exemplos, ou conjunto de aprendizagem; define-se um conjunto F de procedimentos de

Onde p representa a dimensão dos exemplos. Em “data mining”, considera-se que não são conhecidas nem a regra de decisão $P(C|X)$, nem as propriedades do ambiente $P(X)$, nem mesmo a lei subjacente à distribuição $P(X,C)$. Para exprimir essa última restrição, localiza-se num contexto não paramétrico, ou “*distribution-free*”.

Uma **amostra** é um conjunto finito de exemplos obtidos de maneira independente, seguindo a distribuição $P(X,C)$. No curso deste trabalho, fala-se frequentemente de conjunto de aprendizagem ou de conjunto de teste. Trata-se de amostra de exemplos, como foi acima definido. O Anexo A apresenta a amostra de exemplos usada nesta Dissertação.

Um **procedimento de classificação** (ou modelo) é uma aplicação F definida sobre X (descrição dos casos) e com valores em $\{1,2,...,C\}$ (diagnósticos). O objetivo da aprendizagem é descobrir o procedimento de classificação que governa os exemplos. De uma maneira ou de outra, os métodos de aprendizagem indutiva efetuam sempre uma exploração de um espaço previamente fixado de procedimentos de classificação viáveis. Esse espaço será representado por F . No caso dos exemplos binários, considerar-se-á que F é um conjunto de fórmulas lógicas, de forma predeterminada, expressas com ajuda dos operadores booleanos usuais: \wedge (e), \vee (ou), \neg (negação).

Aprender indutivamente, é ao mesmo tempo um processo de cálculo e uma exigência de capacidade preditiva, com respeito ao procedimento de classificação encontrado. O processo pode se resumir, como a seguir: dispõe-se de um conjunto de exemplos, ou conjunto de aprendizagem; define-se um conjunto F de procedimentos de

classificação³; extrai-se de F um “bom” procedimento de classificação. O que se entende por bom? Por um lado, “bom” quer dizer que este procedimento classifica corretamente os exemplos do conjunto de aprendizagem. Mas isso não é tudo. Por outro lado, deseja-se também que este procedimento tenha uma boa capacidade de predizer a classe de um exemplo que não está no conjunto de aprendizagem. Daí vem a exigência preditiva mencionada acima. Classificar corretamente um exemplo, através de um procedimento de classificação, significa que a classe do exemplo coincide com a classe dada pelo procedimento.

Resta definir o que se entende por: “boa capacidade de predizer”. De fato, numerosas definições são possíveis. A que se dará a seguir é a mais simples, e uma das mais comuns.

A frequência de erro, ou taxa de erro, ou ainda taxa de erro aparente, de um procedimento de classificação F é dado por:

$$f_{err}(F) = \frac{err}{n}$$

onde n representa o tamanho do conjunto de aprendizagem, e err é o número de exemplos do conjunto de aprendizagem que são incorretamente classificados por F .

A probabilidade de erro, ou taxa de erro real, é a probabilidade que um procedimento de classificação F classifique incorretamente um exemplo obtido de acordo com $P(X,C)$. Essa probabilidade será representada por $P_{err}(F)$.

Portanto, aprender resume-se a:

³ Nas seções seguintes, quando define-se o procedimento de classificação chamado de “árvore de decisão”, mostra-se em detalhes como obter-se F .

- i. Selecionar em F o procedimento de classificação que minimiza f_{err} . Esse procedimento de classificação será representado por F_{opt} . A dificuldade dessa tarefa é de ordem algorítmica. Para certas classes de procedimentos de classificação essa tarefa não será efetuada dentro de um tempo de cálculo aceitável. Dessa forma, contenta-se em encontrar um procedimento de classificação cuja frequência de erro seja baixa, através de um método aproximativo de IA. Por uma questão de simplificação, continua-se representando essa aproximação por F_{opt} . Nessa Dissertação mostra-se algoritmos indutivos de construção de árvores de decisão.
- ii. Ao mesmo tempo, fica-se satisfeito com o resultado do algoritmo indutivo somente quando se possui garantias de que $P_{err}(F_{opt})$ seja próxima de 0. A seguir dá-se as principais noções estatísticas, assim como um conjunto de resultados, que permitem o melhor entendimento do problema em questão e as restrições que ele induz.

Aspectos Estatísticos

Considere-se um procedimento de classificação F , fixado *a priori*. A lei dos grandes números indica que, quando o tamanho n da amostra aumenta (aqui, n representa o número de casos), a frequência de erro de F , $f_{err}(F)$ converge⁴ para a probabilidade de erro de F , $P_{err}(F)$. Isso de maneira totalmente análoga àquela que se observa quando, no lançamento de uma moeda, obtem-se cara ou coroa: quanto maior o número de lançamentos, mais a frequência de obtenção de cara se aproxima

⁴ Trata-se de uma convergência em probabilidade, isto é, de um comportamento médio. Diz-se que uma estatística X medida sobre uma amostra de tamanho n converge em probabilidade para um valor v quando para todo P , $\lim_{n \rightarrow \infty} P(|X-v| > P) = 0$. Na sequência do texto, quando se fala de convergência, proximidade, distância, etc, fica implícito que situa-se dentro de um quadro probabilístico.

de 0,5. Noutros termos, $f_{err}(F)$ se traduz numa boa aproximação de $P_{err}(F)$, principalmente quando n aumenta.

Infelizmente, esse raciocínio não é verdadeiro quando se trata do procedimento de classificação ótimo F_{opt} , selecionado através de processo de minimização da frequência de erro. De fato, $f_{err}(F_{opt})$ fornece uma visão parcial e frequentemente otimista da probabilidade de erro $P_{err}(F_{opt})$, isto é, ela é claramente mais próxima de zero. Por que razão isso se produz? Por que não se pode ao mesmo tempo selecionar com uma amostra de aprendizagem e julgar com essa mesma amostra.

Um meio de remediar esse problema é a separação de um conjunto independente chamado de amostra ou conjunto de teste. Da mesma maneira, para um procedimento de classificação fixado *a priori*, a frequência de erro de F_{opt} medida a partir de um conjunto de teste, dá uma boa estimativa de $P_{err}(F_{opt})$, notadamente quando o tamanho do conjunto de teste aumenta. Na prática, em “data mining”, dispõe-se de um conjunto fixo de exemplos onde se deve separar o conjunto de aprendizagem do conjunto de teste. Uma primeira idéia simples consiste em dividir a amostra em duas, aprender com metade e testar com a outra metade. Esta não é a melhor solução, salvo se o número de exemplos for muito grande. Uma melhor solução tentaria obter amostras onde a porcentagem das diferentes classes fossem iguais. Vários autores se voltaram para esse problema e propuseram diferentes soluções para estimar a probabilidade de erro permitindo que se use toda a amostra para aprender. O processo de validação cruzada proposto por BREIMEN *et al.* (1983) sempre fornece uma boa estimativa da probabilidade de erro.

Adicione-se à notação de um procedimento de classificação F um parâmetro k , que indica uma medida de complexidade para F , assim, notar-

se-á F_k . Esse novo parâmetro depende de características do espaço F . No caso de árvores de decisão (vide definição detalhada adiante) k pode ser a profundidade das árvores, o número de folhas, etc.. A partir de trabalhos teóricos (VAPNIK & CHERVONENKIS, 1971), chega-se à conclusão que, quanto maior o parâmetro k , menor será a frequência de erro medida sobre o conjunto de aprendizagem. No entanto, quando se trata do conjunto de teste, num primeiro momento a probabilidade de erro diminui com o aumento de k , em seguida entra num patamar onde k aumenta e a probabilidade se mantém inalterada, para finalmente começar a aumentar lentamente com o aumento de k . A Figura 3 representa o comportamento de duas curvas a cerca do parâmetro k . A curva superior representa o comportamento da probabilidade de erro de acordo com VAPNIK & CHERVONENKIS, a inferior representa a frequência de erro. A região hachurada na curva superior denota o ponto onde a probabilidade de erro é mínima, ela se projeta na abscissa, ressaltando a região onde k é ótimo.




Figura 3. Comportamento típico da probabilidade de erro e a frequência de erro em função de k .

Em consequência, para estimar a probabilidade de erro a partir de uma simples amostra, deve-se levar em consideração a complexidade k do procedimento de classificação ótimo, *i.e.* $F_{k,opt}$.

Anteriormente foram apresentados dois aspectos importantes no conceito de aprendizagem indutiva: o problema algorítmico, que é o de encontrar um procedimento de classificação que minimize a frequência de erro, e o problema estatístico, que é o de dotar o procedimento de classificação de poder preditivo vis-à-vis da probabilidade de erro. Agora adicione-se um elemento novo: para melhor resolver os dois problemas acima deve-se levar em consideração as características do espaço de busca, com a finalidade de descobrir a complexidade ideal do procedimento de classificação ótimo. De um lado, o problema estatístico está associado à complexidade do procedimento de classificação ótimo. Por outro lado, a complexidade dos procedimentos de classificação que compõem o espaço de busca, influencia a forma de percorrer esse espaço, *i.e.* o problema algorítmico. GOMES, (1992) trata detalhadamente do problema algorítmico em aprendizagem indutiva.

O Método CART (*Classification and Regression Trees*), proposto por BREIMEN *et al.* (1983), lida de forma elegante com os dois problemas supracitados. Os procedimentos de classificação são representados por estruturas chamadas de árvore de decisão. CART é um algoritmo que, grosso modo, é executado em três passos: construção de uma árvore de complexidade máxima, poda radical da árvore e estimativa da probabilidade de erro através de validação cruzada. A seguir apresenta-se detalhes desse método, que será o método utilizado nessa Dissertação.

O Método CART

A idéia central dos algoritmos de aprendizagem baseados na construção de árvores de decisão binárias é dividir recursivamente os exemplos do conjunto de aprendizagem, com o auxílio dos atributos, até que se obtenha sub-conjuntos de exemplos que sejam suficientemente puros, *i.e.* que contenham quase todos os exemplos de uma mesma classe.

Uma **árvore de decisão binária** é uma árvore cujos nós são representados por atributos booleanos⁵ e arestas (ou ramos) que são rotuladas por 0 ou 1, sim ou não, presença ou ausência, etc.. Um nó terminal (ou folha) representa uma classe (que é o diagnóstico). Um caminho que vai da raiz a uma das folhas representa uma implicação conjuntiva cujas condições são os nós intermediários, associados aos valores das arestas e a conclusão é o diagnóstico associado ao nó terminal. Por exemplo, a Figura 4 representa uma árvore de decisão binária onde pode-se extrair as seguintes implicações: $(A1=0) \rightarrow C1$, $(A1=1 \text{ e } A2=0) \rightarrow C1$ e $(A1=1 \text{ e } A2=1) \rightarrow C2$.

⁵ São aqueles que são descritos por atributos binários. Refere-se a George Boole, matemático e filósofo inglês do século 19.





Figura 4. Árvore de Decisão

Uma divisão de um nó intermediário é determinada por um dos atributos que descrevem os exemplos. Uma divisão binária pode ser vista como uma pergunta que se deve formular a um certo nó para separar o conjunto de exemplos em dois grupos: aqueles que respondem “sim” e aqueles que respondem “não”. Por convenção, quando se trata de árvore binária, os exemplos que apresentam o valor 1 (presença) farão parte do sub-conjunto da direita e os que apresentam valor 0 (ausência) farão parte do sub-conjunto da esquerda. Por exemplo, a divisão fornecida pelo atributo binário $TO\{P,A\}$, pode ser representado pelo diagrama:




A construção de árvore de decisão requer três operadores:

1. Selecionar a melhor divisão de um nó, para colocá-la na raiz, ou nó intermediário.
2. Decidir se o nó é terminal (folha).
3. Atribuir uma classe a um nó terminal.

Uma vez construída a árvore, sabe-se que se deve podá-la para adequar-se à melhor complexidade, conforme visto anteriormente como sendo o problema estatístico. A seguir detalha-se cada uma dessas fases.

Seja L o conjunto dos casos utilizados para aprender. Seja T uma árvore binária construída a partir de L e d um nó intermediário de T , definido pela divisão s . O nó d será representado pelo diagrama:



onde $N(d) \leq |L|$ é o número de exemplos representados por d (na raiz tem-se $N(d) = |L|$), d_e e d_d são respectivamente os nós descendentes da esquerda e da direita, P_e e P_d designam a proporção de $N(d)$ incidente sobre d_e e d_d , respectivamente. Uma sub-árvore T_i da árvore T é obtida após a poda de um ou mais ramos de T . Define-se a proporção de casos da classe $c \in \{1, 2, \dots, C\}$ (nesse trabalho $C=2$) no nó d , por:

$$p(c|d) = \frac{N_c(d)}{N(d)}$$

onde $N_c(d)$ é o número de casos da classe c em d . Deve-se notar que:

$$\sum_{c=1}^C p(c|d) = 1$$

O número de nós terminais (ou folhas) em T , será representado por $|T|$.

Para construir uma grande árvore inicial T_{max} , CART escolhe entre todas as possíveis divisões s , aquela que leva à menor “mistura” de classes no nó, chamado de critério de impureza do nó. Em seguida, impõe a seguinte regra: um nó será considerado terminal quando $N(d) \leq n_0$, onde n_0 é um parâmetro pré-definido. A idéia é fazer $n_0=1$, para que a árvore seja verdadeiramente máxima. Porém, BREIMAN *et al.*

(1983) afirmam que, na prática, $n_0=5$ leva ao mesmo resultado. Outros autores (QUINLAN et al., 1987), com o intuito de abreviar o processo de construção da árvore, param de ramificá-la, quando existe uma predominância de uma classe sobre as outras, considerando-se os casos que incidem no nó.

Escolha da melhor divisão s

A cada nó d da árvore associa-se uma medida de impureza $imp(d)$, que representa o grau de mistura das classes em d . Quanto maior for $imp(d)$, maior será a mistura de classes em d . E um nó é dito “puro” se todos os exemplos incidentes pertencem a uma mesma classe ou o número de casos incidentes no nó seja igual ou menor que 5. Nesse caso inexistente impureza. A impureza de d é dada por:

$$imp(d) = \sum_{i \neq j}^c p(i|d) \cdot p(j|d)$$

Sabendo que uma divisão s consiste em enviar uma parte de $N(d)$ sobre o nó d_e e outra sobre o nó d_d , nas proporções P_e e P_d , a redução da impureza de d é dada por:

$$\Delta imp(s, d) = imp(d) - P_e \cdot imp(d_e) - P_d \cdot imp(d_d)$$

$\Delta imp(s, d)$ representa a diferença entre a impureza do nó pai e a média ponderada das impurezas de seus descendentes imediatos.

A melhor divisão do nó d é, entre todas as divisões possíveis, aquela que leva à maior redução de impureza, ou seja:

$$\Delta imp(s^*, d) = \max(\Delta imp(s, d))$$

Com o intuito de ilustrar os três passos de construção da árvore de decisão, suponha-se a existência de um banco de dados fictício, constituído de 700 casos apresentando os sinais e sintomas contidos na Tabela 1. Desse total 400 casos correspondem a TAPC e 300 a DORL. A Figura 5 apresenta a separação de classes determinada por dois sintomas, PA (paresia facial ou do glossofaríngeo) e DD (dificuldade de deglutição). A classe indicada numa folha é aquela predominante nos casos que incidem em um nó. No caso do sintoma PA nota-se que, quando da sua ausência, foram encontrados 10 casos de TAPC e 295 casos de DORL, encerrando a ramificação da árvore e rotulando o nó terminal como DORL. Dos casos em que existia a presença do sintoma PA, 390 indicam TAPC e 5 indicam DORL, também encerrando a ramificação e rotulando o nó terminal como TAPC. Já o sintoma DD, quando presente, leva à uma forte indicação de TAPC. Porém, quando DD está ausente, não existe predominância de uma classe, deve-se então continuar a ramificação até que haja predominância ou o número de casos incidentes no nó seja igual ou menor do que 5. Nota-se portanto que o sintoma PA tem valor discriminativo superior a DD. Na ocorrência da escolha de DD, como representado na Figura 5, a árvore teria de ser ramificada. Essa ramificação é efetuada através da escolha de um novo sinal ou sintoma, dentre todos os sinais e sintomas, porém considerando-se apenas aqueles casos onde DD é ausente.

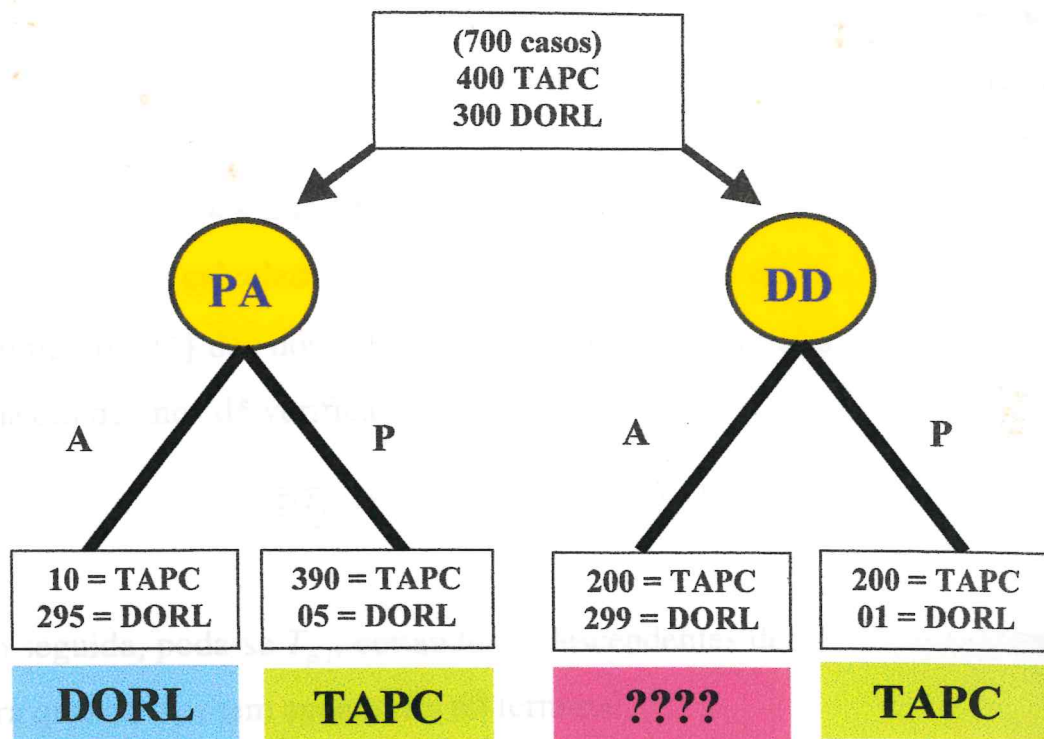


Figura 5. Ilustração do processo de construção da árvore de decisão por CART.

Poda

T_{max} tendo sido construída, deve-se podá-la para encontrar a melhor sub-árvore. CART constrói então uma sequência S de sub-árvores de T_{max} , seja $S = \{T_0, T_1, \dots, T_{p-1}, T_p, \dots, T_t\}$, onde $T_0 = T_{max}$, e T_t é a sub-árvore que é composta somente por um nó terminal. Cada sub-árvore de S é inclusa na sub-árvore que a precede e contém a sub-árvore seguinte.

Para cada nó d da árvore $T_p \in S$, define-se o seguinte critério de poda:

$$\xi(t_p, d) = \frac{MC(d) - MCDT(d)}{N(d) \cdot (NDT(d) - 1)}$$

onde $MC(d)$ é o número de exemplos classificados erroneamente do nó d , $MCDT(d)$ é o número de exemplos classificados erroneamente nos descendentes terminais de d , e $NDT(d)$ é o número de descendentes terminais de d . Dessa forma, quando tem-se T_{p-1} ($p > 0$) e quer-se gerar T_p , o valor de ξ será calculado para cada nó intermediário de T_{p-1} . Marca-se então o conjunto $\{d^*\}$ dos nós d^* que apresentam o menor valor para ξ . Portanto, cada um dos nós d^* verifica:

$$\xi(T_{p-1}, d^*) = \min_{d \in T_{p-1}} (\xi(T_{p-1}, d)), p = 1, \dots, P$$

Em seguida, poda-se T_{p-1} , cortando os descendentes de d^* . O procedimento para quando T_{p-1} tem apenas um nó terminal.

Uma vez obtida a sequência S , deve-se escolher a sub-árvore que minimiza a probabilidade de erro. Para obter essa probabilidade deve-se verificar a taxa de erro de cada sub-árvore em S , usando-se o conjunto de teste ou um processo chamado de *validação cruzada*. Nessa Dissertação, devido ao limitado número de casos disponíveis não é possível separar-se um conjunto de teste, portanto usa-se a validação cruzada.

Validação Cruzada

Quando a quantidade de casos disponíveis não permite dividir-se o número de casos em conjunto de aprendizagem e conjunto de teste, CART emprega a validação cruzada. Esse procedimento permite usar-se a totalidade dos exemplos para aprender e ao mesmo tempo escolher a sub-árvore que minimiza a probabilidade de erro.

A amostra total L será dividida em v sub-amostras disjuntas e de mesmo tamanho, seja $\{L_1, L_2, \dots, L_v\}$. A cada amostra L_i associa-se a outra amostra L^i , complementares em L . Em seguida, a partir de cada amostra L^i constrói-se uma árvore, seja T^i , e uma sequência de sub-árvores S^i , utilizando-se o mesmo procedimento da poda, exposto acima. A estimativa da taxa de erro real de cada sub-árvore em S^i é efetuada com a ajuda do complementar L_i , i.e. L^i é a amostra de aprendizagem e L_i é a amostra de teste.

Para estimar qual é a melhor sub-árvore da sequência S , CART determina quais são as árvores de S^i que mais se assemelham a T_p . A sub-árvore escolhida será aquela que propiciará o valor mínimo do somatório das taxas de erro reais.

A associação da poda e da validação cruzada fornece árvores de complexidade muito reduzida, ao mesmo tempo que apresentam uma taxa de erro real muito reduzida. Isto faz de CART o método escolhido nessa Dissertação.

Relembrando o que foi dito anteriormente, dado um conjunto de casos (ou exemplos) conhecidos pelo diagnóstico confirmado, o objetivo é criar-se um modelo (em linguagem computacional: um classificador) a partir desses exemplos. O modelo obtido deverá ser capaz de diagnosticar corretamente, casos idênticos aos usados para gerá-lo, assim como casos desconhecidos.

Resumindo, os dados são descritos de forma imperfeita. Neste caso, é de se esperar que o modelo gerado seja também imperfeito, uma vez que ele pode ser afetado pelas irregularidades estatísticas presentes na descrição dos casos. Diz-se então que o modelo obtido excede ("*overfit*") o conjunto de casos. Isso significa que o modelo consegue diagnosticar

corretamente quase todos os casos novos idênticos aos usados para gerá-lo, porém é impreciso quando se trata de diagnosticar novos casos desconhecidos. Deste modo, deve-se buscar classificadores que sejam menos ligados à casuística disponível, porém, mais gerais, *i.e.* que consigam definir corretamente o diagnóstico de novos casos. Um modelo mais geral é menos complexo, quanto ao seu tamanho ("*rightfit*"). Em resumo, busca-se um bom compromisso entre complexidade e o número de diagnósticos corretos, considerando-se apenas os casos disponíveis que alimentaram o sistema.

4 RESULTADOS

4.1 Modelo Diagnóstico de Tapc e Dorl

A Tabela 2 apresenta a matriz de frequências, segundo o diagnóstico. O modelo final obtido será avaliado através da comparação entre a hipótese diagnóstica gerada pelo modelo (HTAPC, HDORL) e o real diagnóstico de cada caso (RTAPC, RDORL), testado à luz da validação cruzada (vide capítulo anterior). A acurácia do modelo será dada pela expressão $(PP+NN)/(RTAPC+RDORL)$, *i.e.* o número de casos diagnosticados corretamente pelo modelo, dividido pelo número total de casos. Entenda-se que PP são os casos de TAPC diagnosticados corretamente pelo modelo e NN os casos de DORL igualmente diagnosticados de modo correto, pelo modelo. Essa medida fornece o poder preditivo do modelo. A sensibilidade do modelo a cerca dos casos de tumores do APC é dada pela fórmula $PP/RTAPC$. Portanto, a árvore de decisão obtida será avaliada segundo a acurácia e a sensibilidade.

Tabela 2. Matriz de frequências dos casos de teste (RTAPC,RDORL) versus diagnóstico do modelo (HTAPC,HDORL), onde PP representa os casos de tumores do APC diagnosticados corretamente pelo modelo, NN representa os casos de DORL corretamente diagnosticados pelo modelo, FN são os falsos negativos e FP os falsos positivos.

	RTAPC	RDORL
HTAPC	PP	FP
HDORL	FN	NN

A Figura 6 apresenta a árvore de decisão fornecida pelo CART. A variável que representa paresia (PA, vide Tabela 1), está localizada na raiz da árvore e apresenta, conseqüentemente, o maior poder discriminatório. Vale ressaltar que, dos 121 casos que apresentavam paresia, 117 foram diagnosticados corretamente pelo modelo. Para diagnosticar todos os casos o modelo gerado, além de PA se utiliza de apenas mais três variáveis descritas na Tabela 1, quais sejam: EQ, DF, TO.

Considerando a totalidade dos casos (750), o modelo diagnosticou **corretamente 88,4% (663)** o que representa uma excelente acurácia. A Tabela 3 mostra a matriz de frequências para a árvore da Figura 6. Separando-se apenas os casos de tumores do APC (275), nota-se que a árvore de decisão consegue acertar o diagnóstico de 212 casos (77,09%), o que representa uma boa sensibilidade do modelo para TAPC. Além disso, o número de falsos positivos (FP) foi de apenas 24 em 750, o que corresponde a 3,2% e o de falsos negativos (FN) foi de 8,4%.

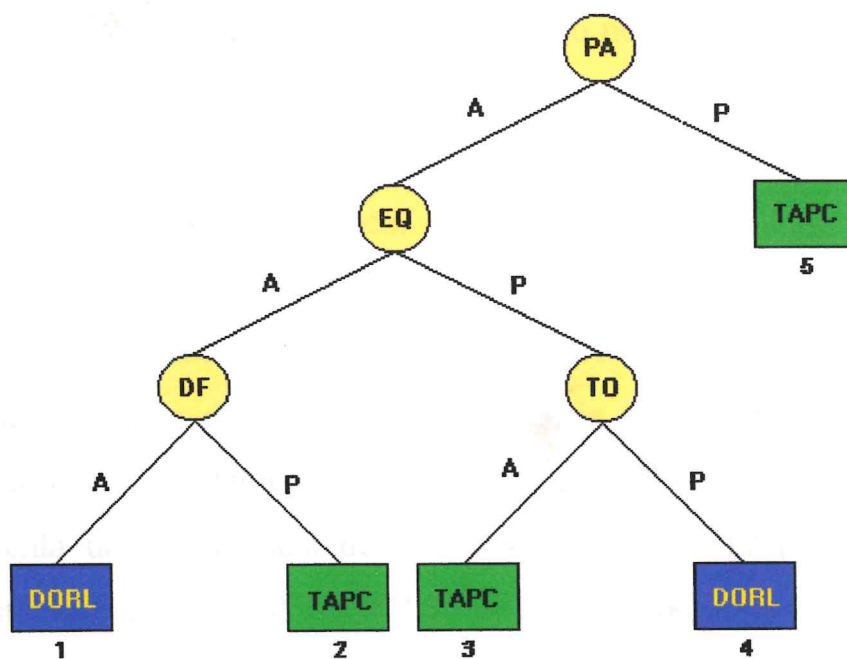


Figura 6. Árvore de decisão fornecida por CART para o modelo de discriminação TAPC, DORL. Rotulando cada ramo tem-se A=Ausência e P=Presença. PA representa paresia dos nervos facial e/ou glossofaríngeo, EQ é comprometimento do equilíbrio (Ataxia, Vertigem, Romberg e Fournier), DF é distúrbio de sensibilidade na face e TO representa tontura. Cada nó terminal é numerado 1-5.

Tabela 3. Matriz de frequências obtida na avaliação da árvore de decisão da Figura 6

	RTAPC	RDORL
HTAPC	212	24
HDORL	63	451

A Figura 7 traduz a importância de cada um dos nós terminais, a cerca do número de casos de TAPC e DORL incidentes em cada classe.

Nota-se que dos cinco nós da árvore, apenas o nó terminal 2 não apresenta relevância diagnóstica, pois a incidência de casos das duas classes é praticamente a mesma. Por outro lado, os nós terminais 1 e 5 são altamente relevantes quanto ao diagnóstico. 450 casos incidem no nó terminal 1, desses, 404 (89,77%) são de DORL e apenas 39 (10,23%) de TAPC, o que leva a árvore a rotular esse nó como DORL, sempre que um caso apresentar ausência de paresia (PA), ausência de distúrbio do equilíbrio (EQ) e ausência de alterações de sensibilidade na face (DF). O nó terminal 5 apresenta uma incidência de 121 casos, desses, 117 (96,70%) foram diagnosticados como TAPC e 4 (3,30%) como DORL. Portanto, o modelo nos indica que a presença de paresia (PA), leva à uma forte possibilidade diagnóstica de TAPC. Ressalte-se o reduzido número de sintomas necessários e suficientes ao diagnóstico.

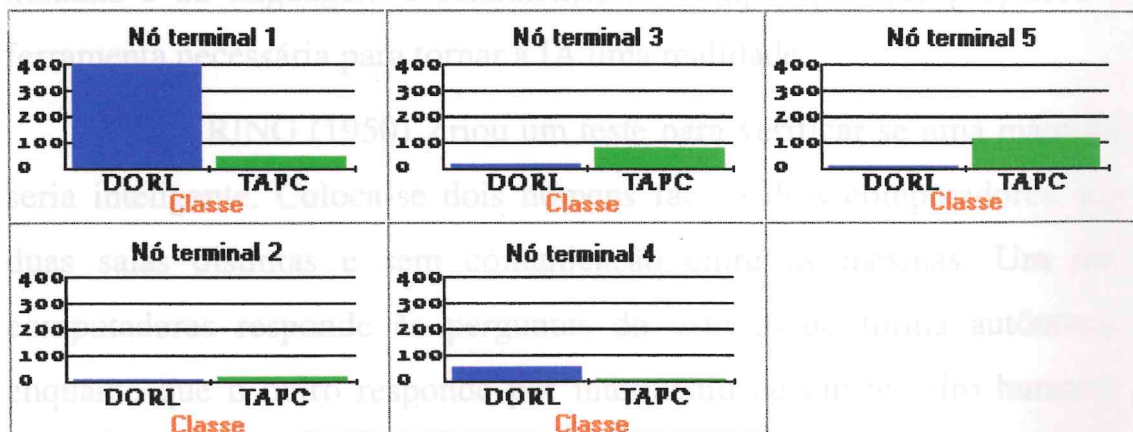


Figura 7. Relevância dos nós terminais representada na árvore da Figura 6.

5 DISCUSSÃO

No capítulo 1 foram apresentadas as diferentes estruturas existentes no APC, cujo comprometimento leva ao aparecimento de inúmeros sinais e sintomas, difíceis de permitirem um diagnóstico sem exames complementares, bem como foi mostrada uma visão geral dos aspectos cronológicos da IA. Naturalmente que todo relato histórico peca pela omissão de nomes. Por outro lado não é escopo dessa Dissertação esgotar os aspectos históricos da ciência da computação, em particular da IA. Não seria exagero, contudo, dizer-se que, sendo a IA uma ciência multidisciplinar, valeu-se de 2.000 anos de fundamentação filosófica, de secular conhecimento matemático que permitiu estruturar o raciocínio e a lógica, da psicologia que forneceu os fundamentos do estudo da mente humana e da linguagem e finalmente, da computação que propiciou a ferramenta necessária para tornar a IA uma realidade.

TURING (1950), criou um teste para verificar se uma máquina seria inteligente. Coloca-se dois homens face a dois computadores, em duas salas distintas e sem comunicação entre as mesmas. Um dos computadores responde às perguntas do usuário de forma autônoma, enquanto que o outro responde por intermédio de um terceiro humano. Em seguida, começa-se uma sessão de perguntas e respostas entre os homens e as máquinas. Se, ao fim dessa sessão, não for possível distinguir qual é o computador autônomo, essa máquina seria dita inteligente.

Dentre as diversas definições dadas à IA por renomados nomes da área, uma análise crítica das mesmas permite concluir que as definições de Haugeland, Belmann, Charniak, McDermott e Winston são

relacionadas com o processo do pensamento e do raciocínio enquanto que as definições de Kurzweil, Rich e Knight, Schalkoff, Luger e Stubblefield são relacionadas com o comportamento. Por outro lado Haugeland, Belmann, Kurzweil, Rich e Knight se baseiam na performance humana, enquanto que as definições dos demais autores se relacionam com a racionalidade. Dessas definições apreende-se que IA está voltada para:

1. a criação de um sistema que pense como o Homem. Exemplo disto é encontrado no trabalho de Newell e Simon (1961) que criaram o “GPS – *General Problem Solver*”;
2. um sistema que aja como o Homem, como o computador utilizado para o Teste de Turing (TURING, 1950);
3. um sistema que pense racionalmente – linha de pesquisa iniciada e desenvolvida pelos filósofos gregos. PLATÃO (347 AC), descrevendo o colóquio entre Sócrates e seu discípulo Euthifro, relata o questionamento de Socrates sobre o que é pio e o que não é pio. Naquela ocasião Sócrates criava um algoritmo. Aristóteles tentou codificar o pensamento correto com os seus silogismos que são o modo de se obter conclusões mecanicamente.

Na realidade IA é uma ciência em que estão envolvidas: Biologia, Filosofia, Lingüística, Física, Matemática, Engenharia de computação, Neuro-computação, etc.

Uma das tarefas a que se destina a IA é a de extrair conhecimento a partir de dados. Este processo, como foi dito, é computacionalmente difícil (diz-se, NP-difícil), *i.e.* não existe um programa de computador que forneça todo o conhecimento existente numa

relacionadas com o processo do pensamento e do raciocínio enquanto que as definições de Kurzweil, Rich e Knight, Schalkoff, Luger e Stubblefield são relacionadas com o comportamento. Por outro lado Haugeland, Belmann, Kurzweil, Rich e Knight se baseiam na performance humana, enquanto que as definições dos demais autores se relacionam com a racionalidade. Dessas definições apreende-se que IA está voltada para:

1. a criação de um sistema que pense como o Homem. Exemplo disto é encontrado no trabalho de Newell e Simon (1961) que criaram o “GPS – *General Problem Solver*”;
2. um sistema que aja como o Homem, como o computador utilizado para o Teste de Turing (TURING, 1950);
3. um sistema que pense racionalmente – linha de pesquisa iniciada e desenvolvida pelos filósofos gregos. PLATÃO (347 AC), descrevendo o colóquio entre Sócrates e seu discípulo Euthifro, relata o questionamento de Socrates sobre o que é pio e o que não é pio. Naquela ocasião Sócrates criava um algoritmo. Aristóteles tentou codificar o pensamento correto com os seus silogismos que são o modo de se obter conclusões mecanicamente.

Na realidade IA é uma ciência em que estão envolvidas: Biologia, Filosofia, Lingüística, Física, Matemática, Engenharia de computação, Neuro-computação, etc.

Uma das tarefas a que se destina a IA é a de extrair conhecimento a partir de dados. Este processo, como foi dito, é computacionalmente difícil (diz-se, NP-difícil), *i.e.* não existe um programa de computador que forneça todo o conhecimento existente numa

base de dados, dentro de um tempo aceitável. Nesse caso, deve-se buscar métodos aproximativos que, em geral, são estudados em áreas como aquisição automática de conhecimento, aprendizagem automática, reconhecimento de padrões e estatística. O termo mais usado para o processo de descoberta do conhecimento como um todo é “Garimpagem de Dados”, do inglês “Data Mining”. A rigor, “Data Mining” é o conjunto de métodos usados no processo de descoberta de conhecimento, composto de várias fases. Nessa Dissertação adota-se o termo “Garimpagem de Dados” e “Data Mining” indiscriminadamente para representar o processo de descoberta de conhecimento como um todo.

Vêm sendo armazenados, a partir do advento do computador, os dados necessários ao funcionamento de laboratórios, hospitais, clínicas etc. tanto os relacionados ao aspecto financeiro e administrativo, quanto ao aspecto científico, propriamente dito. Com o desenvolvimento tecnológico e o barateamento dos computadores, de um modo geral, grande volume de informações encontra-se em enormes Bancos de Dados. Referidas informações, somente são mantidas em Bancos de Dados enquanto necessárias ao desempenho das atividades quotidianas. Não somente os laboratórios, hospitais e clínicas, mas também e principalmente, o médico em seu consultório, deve manter programa sistemático de coleta de dados, para, mais tarde, obter conhecimento, através do processo de “garimpagem de dados”. A vantagem de se armazenar grande volume de casos depende da habilidade de se extrair conhecimento a partir desses casos, para se alcançar objetivos científicos através de decisões inteligentes. A Figura 8 ilustra o processo de transformação dos dados, enfatizando o volume e o valor agregado dos dados, que podem ser

transformados em informação. Essa última podendo vir a constituir-se conhecimento que poderá ser aproveitado, através de decisões estratégicas inteligentes.



Figura 8. Relação entre dados, informação, conhecimento e a tomada de decisão estratégica, de acordo com o volume de armazenamento e o valor

Os “software” de consulta a bases de dados, integrados à maioria dos sistemas gerenciadores de bancos de dados (SGBD) conseguem transformar os dados em informação. Por exemplo, numa base onde estão armazenados dados que dizem respeito à procura da Leishmaniose na serra de Guaramiranga, pode-se formular a seguinte pergunta: Quantas moradias do tipo XYZ mostraram presença do mosquito transmissor da Leishmaniose tegumentar? Ao consultar o banco de dados o sistema gerenciador de Bancos de Dados nos fornecerá uma resposta precisa. O que o sistema fez foi simplesmente, percorrer uma série de tabelas para responder à consulta. Agora, suponha-se que se obteve o seguinte conhecimento estratégico a partir dos dados : Todas as casas construídas à beira de cursos d’água há mais de quinze anos foram infestadas pelo

mosquito em 1999. Trata-se agora de um padrão existente nos dados que não poderia ter sido obtido pelo médico através de simples consulta à base de dados, pelo fato de se desconhecer quais elementos comporiam a consulta antes de realizá-la.

Fayyad, Piatetsky-Shapiro e Smyth (1996) definem “data mining” como:

“o processo não trivial de identificação de padrões válidos, originais, potencialmente úteis e legíveis a partir de dados”.

O termo “processo” implica que existem muitos passos, envolvendo: preparação dos dados, busca de padrões, avaliação do conhecimento, visualização, e outros. O processo é não trivial se considerarmos que os padrões são difíceis de ser extraídos e se encontram ocultos na massa de dados empregada. De acordo com esta definição, o termo “padrões” adquire um sentido mais amplo, podendo ser representado por árvores de decisão, conjuntos, modelos, estruturas de dados, etc. Os padrões descobertos devem ser:

- a) válidos para novos dados não incluídos naqueles usados para extrair os padrões, com um certo grau de certeza;
- b) originais;
- c) úteis para o usuário;
- d) finalmente, a legibilidade do conhecimento adquirido é questão *sine qua non* para o sucesso do processo e é considerado assunto onde as pesquisas ainda devem progredir bastante no sentido de fazer o usuário melhor visualizar os padrões descobertos.

É importante afirmar que a cada dia novos métodos são criados visando melhorar os resultados do processo de descoberta do conhecimento

a partir de dados, porém vários tópicos ainda constituem desafio para os pesquisadores das áreas de Banco de dados e aprendizagem automática. Entre os desafios pode-se citar: grandes bases com mais de 100 terabytes (10^{12} bytes), complexidade dos padrões gerados, alta dimensionalidade e paralelismo, entre outros.

Como foi visto no Capítulo 3, o processo de descoberta do conhecimento é interativo e iterativo, envolvendo vários passos e várias decisões a serem tomadas pelo usuário.

Esse estudo mostrou ser possível a realização de trabalho multidisciplinar, abrindo uma enorme avenida de pesquisa científica entre a área médica e a área de ciência da computação. Isso reforça o interesse que profissionais médicos devem ter na coleta de dados do seu *métier*.

Os resultados aqui relatados são animadores. Eles demonstram que árvores de decisão de alta performance podem ser geradas a partir de dados que apresentam várias formas de ruídos, conforme discutido ao longo desse estudo. Ademais, o fato de se dispor de um número maior de casos associados a um ou outro diagnóstico, não significou perda de acurácia da árvore de decisão gerada. Ou seja, a indiscutível prevalência de casos de DORL em relação aos casos de TAPC, não se constituiu um óbice à obtenção de um modelo com boa capacidade discriminatória.

Além dessa boa capacidade discriminatória entre TAPC e DORL, o modelo proposto não envolveu variáveis (sinais e sintomas) obtidas através de exames complementares invasivos ou não, nem através de estudo radiológico. São variáveis obtidas exclusivamente no decorrer da colheita da história clínica do paciente. O modelo é de grande interesse como indicador do provável diagnóstico entre TAPC e

DORL, notadamente quando da espera dos resultados de exames complementares ou na impossibilidade de realizá-los.

O modelo, representado pela árvore de decisão ilustrada na Figura 6, apresenta acurácia elevada (88,40%) quando se trata de discriminar casos de TAPC e DORL.

Com o presente modelo o processo diagnóstico diferencial entre TAPC e DORL na clínica neurológica ou otorrinolaringológica pode, ser fortemente sugerido apenas com a análise de quatro (ou menos) variáveis. Vale notar que, segundo o modelo proposto, a determinação de presença de paresia já indica, com possibilidade de acerto de **96,70%**, que o paciente pode apresentar processo expansivo na região do APC. Por outro lado, a ausência de paresia se acompanhada de ausência de distúrbio do equilíbrio e dor (ou anestesia) na face indica fortemente o diagnóstico de doença otorrinolaringológica. O modelo dá ainda outros caminhos para se diferenciar TAPC de DORL. Nenhum neurologista ou otorrinolaringologista diante de casos com relato de um ou mais dos vinte e um sinais e sintomas descritos na tabela das variáveis, será capaz de afirmar com certeza se está diante de um caso de TAPC ou de DORL, sem valer-se de exames complementares radiológicos de alto custo.

Surpreende o médico em geral a afirmação de que um único sinal ou sintoma, *in casu* paresia (PA), seja um forte indicativo da existência de um tumor no APC. Contudo, vale ressaltar que a diferenciação foi realizada apenas entre dois grupos de afecções (DORL e TAPC). Ademais, o modelo proposto tem um percentual de falha de 9,78%.

FOGEL *et al.* (1998) usaram um método de IA, chamado de redes neurais artificiais, para discriminar entre tumores malignos e benignos da mama. Nesse trabalho os autores usaram 216 casos, 111 de tumores malignos e 105 benignos, descritos através de 12 características radiográficas. O diagnóstico da casuística foi confirmado através de histopatologia. A acurácia do modelo proposto é de 84%, com especificidade de 62% (maligno) e sensibilidade de 92% (benigno). Apesar da utilização de método diverso daquele utilizado nessa Dissertação, assim como um número menor de casos, o modelo proposto encontrou resultados bastante similares ao presente estudo.

OHMANN *et al.* (1996) avaliaram seis métodos indutivos (ID3, NewID, PRISM, CN2, C4.5 e ITRULE), aplicados ao diagnóstico de dor abdominal. A investigação foi baseada num banco de dados com 1254 casos, 46 sinais e sintomas, e 15 diferentes possíveis diagnósticos. Um conjunto de teste com 415 casos foi utilizado para avaliar a acurácia dos métodos. Segundo os autores, os resultados dos seis métodos não diferiram significativamente, com acurácia variando entre 43% e 48%. Ademais, os resultados, comparados com o grau de acerto de métodos computacionais anteriormente utilizados, não indica melhoria a favor dos métodos de IA. Esse fato é creditado à alta dimensionalidade dos dados (46 sintomas não binários), com o grande número de classes (15 diferentes diagnósticos) e com a complexidade do modelo obtido. Nessa Dissertação, a dimensionalidade dos dados é menor (21 sinais e sintomas binários), o número de classe é de apenas duas e o método utilizado (CART) preza por fornecer árvores de decisão com baixa complexidade.

O fato do presente modelo dispensar exames complementares de alto custo, para sugerir com bastante acurácia o diagnóstico de TAPC ou de

DORL, indiscutivelmente tem um valor social. Isto porque há diminuição dos custos médicos.

Por outro lado, referido modelo abrevia o tempo que pacientes de regiões com menor suporte diagnóstico levavam para obterem uma indicação precisa de exame neuro-radiológico.

Finalmente, a grandeza de uma ciência não se mede no incomensurável conhecimento de suas teorias, mas na aplicabilidade do mesmo ao bem-estar da humanidade. Assim, a conjunção da área médica com a da Ciência da Computação engrandece esses dois ramos do conhecimento humano.

No Anexo B, encontra-se relato de outro experimento efetuado, usando-se subconjunto da casuística aqui apresentada. Nesse experimento, emprega-se os casos diagnosticados como neurinoma do acústico e epidermóide, para, através de uma árvore de decisão, discriminar entre esses dois tipos histológicos. Os resultados indicam uma acurácia de 82,18%

6 CONCLUSÃO

1. O modelo obtido dispensa a utilização de exames complementares invasivos ou não , bem como de exames radiológicos, na tarefa de apoio ao diagnóstico entre TAPC e DORL, de forma legível e precisa.
2. O modelo gerado fornece uma indicação mais racional para a solicitação de exames neuroradiológicos, com redução nos custos médicos.
3. O modelo obtido identifica padrões válidos, originais, potencialmente úteis e perfeitamente legíveis.
4. O sucesso na utilização de métodos de indução depende de um cuidadoso processo de preparação de dados.
5. O presente estudo comprova a utilidade no trabalho conjunto entre médicos e setores da computação, notadamente da IA.

SUMMARY

Data concerning the most varied aspects of the most different pathologies which are present in the human being are accumulating in vertiginous speed in all countries of the world. Modern technology, which is in top of the universal democratization of knowledge, allows patent and relatively easy access to these data. A highlight of this technology is Internet, which made it easy to access information available only to specialists a short time ago. However, in spite of the proteiform aspect of the multiple signs and symptoms of the different pathologies that afflict Man, the search of this strategic knowledge from these data banks is an arduous task, even with the use of the most advanced computers presently available. Thanks, however, to the processes of artificial intelligence (AI) it is possible, even using low performance computers, to gather knowledge from these data and this has been evidenced in various branches of medical domain. This dissertation presents process to obtain a model to help diagnose Cerebelum-Pontine Angle (CPA) tumors using AI techniques. Based on the casuistry that fed the system, a model that presents good accuracy (88.4%) where we can acquire a discriminating diagnostic certainty between CPA tumors versus ear, nose and throat diseases, without using any imaging techniques or invasive procedures. The possibility to establish a difference between CPA tumors and ear, nose, and throat diseases without using expensive and refined neuroradiologic complementary exams will make it possible to lower the diagnostic costs significantly. On the other hand, it will shorten the time a patient generally takes to acquire a diagnostic certainty between the two kinds of diseases. Besides that, it is now possible to establish standards for the requesting of NMR and CT, in cases where it is suspected the existence of CPA tumors, allowing a more reasonable reference of patients from a less developed center to one which has sophisticated complementary exams available. There is a great social and economic significance in this research.

7 REFERÊNCIAS

- ASAWAVICHANGINDA, S., VAEWVICHIT, K., Taecholarn C. cerebellopontine angle meningiomas with primary otologic symptoms. **J. Med. Assoc. Thai.**, v. 80, p. 603-608, 1997.
- BAGULEY, D.M., BEYNON, G.J., GREY, P.L., HARDY, D.G., MOFFAT, D.A. Audio-vestibular findings in meningioma of the cerebello-pontine angle: a retrospective review. **J. Laryngol. Otol.**, v. 3, p. 1022-1026, 1997.
- BEHAR, P.M., DOLAN, R., DASTUR, K., MARRANGONI, A.G., NAYAK, N. Fibrovascular lipoma of the cerebellopontine angle mimicking trigeminal neuralgia. **Ear Nose Throat J.**, v. 1, p. 58-60, 1998.
- BELLMAN, R.E. apud RUSSEL, S.J, NORVIG, P. **Artificial intelligence: a modern approach**. Upper Saddle River: Prentice-Hall, 1995.
- BENABID, A.L., KOUDSIE, A., ASHRAF, A., HOFFMANN, D., KEBAS, J.F. Robotics in neurosurgery . In: ANNUAL MEETING OF GERMAN SOCIETY OF NEUROSURGERY, 49., 1998, Hannover. **Abstract...** Hanover, 1998.
- BREIMAN, L., FRIEDMAN, J.H., OLSHEN, R.A., STONE, C.J. **Classification and regression trees**. Belmont: Wadsworth, 1984.
- CAMBIER, J., MASSON, M., DEHEN, H., **Manual de neurologia**. 2. ed. Rev. Rio de Janeiro: Masson, 1988. cap. 3: Semiologia dos nervos cranianos, p. 88.
- CHARNIAK, E., McDERMUTT, D. apud RUSSEL, S.J, NORVIG, P. **Artificial intelligence: a modern approach**. Upper Saddle River: Prentice-Hall, 1995.
- COMEY, C.H., KONDZIOLKA, D., HOWARD, Y. Regional parenchymal enhancement with mixed cavernous/venous malformation of the brain. Case report. **J. Neurosurg.**, v. 86, p. 154-158, 1997.
- DAVID, M., POURPRE, H., LEPOIRE, J., DILENGE, D. **Neuro-**

- chirurgie.** Paris: Flammarion, 1961. chap. 5, pt. 3: Tumeurs issues des troncs nerveux intracrâniens: neurinomes, p.400-411.
- GOMES, F. C., GASCUEL, O. SDL, a stochastic algorithm for learning decision lists with limited complexity. **Ann. Math. Artif. Intell.**, v. 10, p. 281-302, 1994.
- DEL BRUTTO, O.H. Albendazole therapy for subarachnoid cysticerci: clinical and neuroimaging analysis of 17 patients. **J. Neurol. Neurosurg. Psychiatr.**, v. 62, p. 659-661, 1997.
- FAYYAD, U., PIATETSKY-SHAPIO, G., SMYTH, P. The KDD process for extracting useful knowledge from data. **CACM**, v. 11, p. 27-34, 1996.
- FOGEL, D.B., WASSON III, E.C., BOUGHTON, E.M., PORTO, V.W. Evolving artificial neural networks for screening features from mammograms. **Artif. Intell. Med.**, v. 14, p. 317-326, 1998.
- FOLKER, R.J., MEYERHOFF, W.L, RUSHING, E.J. Aggressive papillary adenoma of the cerebellopontine angle: case report of an endolymphatic sac tumor. **Am. J. Otolaryngol.**, v. 18, p. 135-139, 1997.
- GALL, C., BUTTNER, A., BISE, K., STEIGER, H-J. Primary intracranial metatypical basak cell carcinoma: case report. **Neurosurgery**, v. 41, p. 279-282, 1997.
- GIBAUD, B., GARLLATTI, S., BARILLOT, C., FAURE, E. Computerized brain atlases as decision support systems: a methodological approach. **Artif. Intell. Med.**, v. 14, p. 83-100, 1998.
- HAUGELAND, J. apud RUSSEL, S.J, NORVIG, P. **Artificial intelligence: a modern approach.** Upper Saddle River: Prentice-Hall, 1995.
- HEERGOZ, J.Á., BAILEY, S., MEYER, J. Vascular loops of the internal auditory cannal: a diagnostic dilemma. **Am. J. Otol.**, v. 18, p. 26-31, 1997.
- HONAVAR, V., UHR, L. **Artificial intelligence and neural networks, steps toward principles integration.** San Diego: Academic Press,

1994. cap. 01, p. 21.

- INNOCENT, P.R., BARNES, M., JOHN, R. Application of fuzzy ART/MAP and MinMax/MAP neural network models to radiographic image classification. **Artif. Intell. Med.**, v. 11, p. 241-263, 1997.
- ITO, K., KURITA, H., SUGASAWA, K., MIZUNO, M., SASAKI, T. Analyses of neuro-otological complications after radiosurgery for acoustic neurinomas. **Int. J. Radiat. Oncol. Biol. Phys.**, v. 39, p. 983-988, 1997.
- JALLO, G.I., WOO, H.H., MESHKI, C., EPSTEIN, F.J., WISOFF, J.H. Araochnoid cysts of the cerebello contine cngle: diagnosis and surgery. **Neurosurgery**, v. 40, p. 31-38, 1997.
- JURISICA, I., MYLOPOULOS, J., GLASGOW, J., SHAPIRO, H., CASPER, R.F. Case-based reasoning in IVF: prediction and knowledge mining. **Artif. Intell. Med.**, v. 12, p. 1-24, 1998.
- KMOROWSKI, J., ØHRN, A. Modelling prognostic power of cardiac tests using rough sets. **Artif. Intell. Med.**, v. 15, p. 167-191, 1999.
- KOHAN, D., DOWNEY, L.L., LIM, J., COHEN, N.L., ELOWITZ, E. Uncommon lesions presenting as tumors of the internal auditory cannal and cerebello pontine angle. **Am. J. Otol.**, v. 18, p. 386-392, 1997.
- KRAUSS, J.K., SEEGER, W., JANKOVIC, J. Cervical dystonia associated with tumours of the posterior fossa. **Mov. Disord.**, v. 12, p. 443-447, 1997.
- KUO, T.C, JACKLER, R.K, WONG, K., BLEVINS, N.H., PITTS, L.H. Are acoustic neuromas encapsulated tumors?. **Otolaryngol. Head Neck Surg.**, v. 117, p. 606-609, 1997.
- KURZWEIL, R. apud RUSSEL, S.J, NORVIG, P. **Artificial intelligence: a modern approach**. Upper Saddle River: Prentice-Hall, 1995.
- LANG, J. **Clinical anatomy of the posterior cranial fossa and its foramina**. Stuttgart: Georg Thieme Verlag, 1991. p. 83-84.
- LATHORP, R.H., STEFFEN, N.R., RAPHAEL, M.P., et al. Knowledge-based avoidance of drug-resistant HIV mutants. **AI Magazine**, v. 20,

p. 13-25, 1999.

LAVRAC, N. Selected techniques for data mining in medicine. **Artif. Intel. Med.**, v. 16, p. 3-23, 1999.

LUGER, G.F., STUDBLEFIELD, W.A. apud RUSSEL, S.J, NORVIG, P. **Artificial intelligence: a modern approach**. Upper Saddle River: Prentice-Hall, 1995.

MACHADO, A.B.M. **Neuroanatomia funcional**. Rio de Janeiro: Atheneu, 1974. cap. 11: Nervos cranianos, p. 101

MANTER, J. T., **Neuroanatomia y neurofisiologia clinicas**. Mexico: Interamericana, 1960. cap. 8: Bulbo, protuberancia y mesencéfalo, p. 40-41.

MATTHIES, C., SAMII, M. Direct brainstem recording of auditory evoked potentials during vestibular chivannoma ressection: nuclear BAEP recording. Technical notes and preliminary results. **J. Neurosurg.**, v. 86, p. 1057-1062, 1997.

MEHTA, J.S., SHARR, M.M. Oncology in focus. An unusual cause of acute labyrithine failure. **J. Laryngol. Otol.**, v. 112, p. 193-195, 1998.

MEYER, B., SCHALLER, C., VAN ROOST, D., SCHRAMM, J. Benefits and pitfalls of neuronavigation in neurosurgical routine - a critical summary after a consecutive series of 120 patients. . In: ANNUAL MEETING OF GERMAN SOCIETY OF NEUROSURGERY, 49., 1998, Hannover. **Abstract...** Hanover, 1998.

MONSELL, E.M., CODY, D.D., SPICKLER, E., WINDHAM, J.P. Segmentation of acoustic neuroma with magnetic resonance imaging and eigen image filtring. **Am. J. Otol.**, v. 18, p. 602-607, 1997.

NATHOO, N., NADVI, S.S., VAN DELLEN, J.R. Infratenotiral empyema: analysis of 22 cases. **Neurosurgery**, v. 41, p. 1263-1269, 1997.

NOGUCHI, Y., KOMATSUZAKI, A., YAMADA, I., OKUNO, H., HARAGUCHI, H. Radiology in focus vestibular schwannoma showing a dural tail on contrast-enhanced magnetic resonance images. **J. Laryngol. Otol.**, v. 111, p. 877-879, 1997.

- OHMANN, C., MOUSTAKIS, V., YANG, Q., LANG, K. Evaluation of automatic knowledge acquisition techniques in the diagnosis of acute abdominal pain. **Artif. Intell. Med.**, v. 8, p. 23-36, 1996.
- PLATO. **The last days of Socrates**. Middlesex: Penguin Books, 1954.
- POGGIO, T., BEYMWE, D. Learning to see. **IEEE Spectrum**, p. 60-69, maio, 1996.
- QUINLAN, J.R., COMPTON, P.J., HORN, K.A., LAZARUS, L. **Inductive knowledge acquisition: a case study. In application of expert systems**, Addison Wesley: J.R. Quinlan, 1987;157-173.
- RABISCHONG, P. Present and future of surgical robotics. A robionic concept. . In: ANNUAL MEETING OF GERMAN SOCIETY OF NEUROSURGERY, 49., 1998, Hannover. **Abstract...** Hanover, 1998.
- RHOTON JR, A.L. Microsurgical anatomy of acoustic neuroma. **Neurol. Res.**, v. 6, 3-21, 1984.
- _____. Microsurgical anatomy of the brainstem surface facing na acoustic neuroma. **Surg. Neurol.**, v. 25, p. 26-39, 1986.
- RICH, E., KNIGHT, K. apud RUSSEL, S.J, NORVIG, P. **Artificial intelligence: a modern approach**. Upper Saddle River: Prentice-Hall, 1995.
- RUSSEL, S.J, NORVIG, P. **Artificial intelligence: a modern approach**. Upper Saddle River: Prentice-Hall, 1995.
- SANFORD, R.A., KUN, L.E., HEIDEMAN, R.L., GAJJAR, A. Cerebellar pontine angle ependymoma in infants. **Pediatr. Neurosurg.**, v. 27, p. 84-91, 1997.
- SCHALKOFF, R.C. apud RUSSEL, S.J, NORVIG, P. **Artificial intelligence: a modern approach**. Upper Saddle River: Prentice-Hall, 1995.
- SHINOAMI, M., YAMASOBA, T., SASAKI, T. Internacional case reports. **Otolaryngol. Head Neck Surg.**, v. 118, p. 276- 279, 1996.
- SHISHIBA, T. Follow-up study of a patient with neurilemmomatosis. **J.**

- Am. Acad. Dermatol.**, v. 37, p. 797-799, 1997.
- TOFFANO-NIOCHE, C., BEROULE, D., TASSIN, J.P. A functional model some Parkinson's disease symptoms using a guided propagation network. **Artif. Intell. Med.**, v. 14, p. 237-258, 1998.
- TURING, A.M. apud RUSSEL, S.J, NORVIG, P. **Artificial intelligence: a modern approach**. Upper Saddle River: Prentice-Hall, 1995.
- VAPNIK, V.N., CHERVONENKIS, Y. **On the uniform convergence of relative frequencies of events to their probability. Theory of Probability and its Applications**, Chap. 16, 1971, p. 264-280.
- WEISSMAN, J.L. Imaging of Meniere's disease. **Otolaryngol. Clin. North Am.**, v. 30, p. 1105-1116, 1997.
- WINSTON, P.H. apud RUSSEL, S.J, NORVIG, P. **Artificial intelligence: a modern approach**. Upper Saddle River: Prentice-Hall, 1995.
- ZEITOUNI, A.G., ZAGZAG, D., COHEN, N.L. Meningioma of the internal auditory canal. **Ann. Otol. Rhinol. Laryngol.**, v. 106, p. 657-661, 1997.
- ZUPAN, B., DZEROSKI, S. Acquiring background knowledge for machine learning using function decomposition: a case study in rheumatology. **Artif. Intell. Med.**, v. 14, p. 101-117, 1998.

8 ANEXOS

ANEXO A

Planilha dos Casos

ID	SX	IQ	Z8	PS	D5	D9	DF	D8	DD	EM	EQ	CE	D6	PA	TO	SF	S9	DI	NI	OU	D
58	M		A	A	A	A	A	A	A	A	A	A	A	P	A	A	A	A	A	A	TAPC
63	M	24	A	A	A	A	P	P	A	A	A	A	A	A	A	A	A	A	A	A	TAPC
29	F	24	A	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	TAPC
51	M	3	A	A	A	A	A	P	A	A	P	A	A	A	A	A	A	A	A	A	TAPC
36	F	7	A	A	A	A	P	A	A	A	A	P	A	A	A	A	A	A	A	A	TAPC
33	M		A	A	A	A	P	P	A	A	A	A	A	A	A	A	A	A	A	A	TAPC
32	F	4	A	A	A	A	A	A	A	P	P	A	A	A	A	A	A	A	A	A	TAPC
39	F	8	A	A	A	A	A	P	A	P	P	A	A	A	A	A	A	A	A	A	TAPC
41	F	16	A	A	A	A	A	P	A	A	P	A	P	A	A	A	A	A	A	P	TAPC
37	F	84	A	A	A	A	P	P	A	A	P	P	A	A	A	A	A	A	A	P	TAPC
56	F	60	A	A	A	A	A	A	A	A	P	A	A	A	A	A	A	A	A	A	TAPC
57	F	36	A	A	A	A	A	P	A	A	P	P	A	A	A	A	A	A	A	A	TAPC
19	F	2	A	A	A	A	A	A	A	A	P	P	P	P	A	A	A	A	A	A	TAPC
66	M	2	A	A	A	A	P	P	A	A	P	A	A	P	A	A	A	A	A	A	TAPC
36	M	72	A	A	A	A	P	P	A	A	A	A	A	P	A	A	A	A	A	A	TAPC
31	F	96	A	A	A	A	P	P	A	A	A	A	A	A	A	A	A	A	A	A	TAPC
45	F	108	A	A	A	A	A	P	A	A	P	A	A	A	A	A	A	A	A	A	TAPC
30	M	24	A	A	A	A	P	P	A	A	P	P	A	A	A	A	A	A	A	A	TAPC
63	M	10	A	A	A	A	A	A	A	A	A	A	P	A	A	A	A	A	A	A	TAPC
47	F	2	A	A	A	A	A	P	A	A	A	P	A	A	A	A	A	A	A	A	TAPC
32	F	6	A	A	A	A	P	P	A	A	A	P	A	A	A	A	A	A	A	P	TAPC
28	M	24	A	A	A	A	A	P	A	P	P	P	A	A	A	A	A	A	A	P	TAPC
45	M	36	A	A	A	A	A	P	A	A	A	A	A	P	A	A	A	A	A	A	TAPC
52	F	24	A	A	A	A	P	P	A	A	P	A	A	A	A	A	A	P	A	P	TAPC
24	M	12	A	A	A	A	A	A	A	A	A	A	P	A	A	A	A	A	A	P	TAPC
27	M	1	A	A	A	A	P	A	A	A	P	A	A	A	A	A	A	A	A	A	TAPC
27	F	3	A	A	A	A	A	P	A	A	P	P	A	A	A	A	A	A	A	P	TAPC
51	M	4	A	A	A	A	A	P	A	P	P	A	A	A	P	A	A	A	A	A	TAPC
71	F	12	A	A	A	A	P	A	A	A	P	A	A	A	A	A	A	A	A	A	TAPC
54	F	16	A	A	A	A	A	P	A	A	P	A	A	A	A	A	A	A	A	A	TAPC
29	F		A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	A	TAPC
32		12	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	A	TAPC
55	M	84	A	A	A	A	A	P	A	A	A	A	A	P	A	A	A	A	A	A	TAPC
49	F	240	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	P	A	TAPC
29	M		P	A	A	A	A	A	A	A	A	A	A	A	A	A	A	A	P	A	TAPC
27	M	3	A	A	A	A	P	P	A	A	P	A	A	P	A	A	A	A	A	A	TAPC
45	F		A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	A	TAPC
52	F	4	A	A	A	A	A	P	A	A	P	A	A	A	A	A	A	A	A	P	TAPC
36	M	96	A	A	A	A	A	P	A	A	P	A	A	A	A	A	A	A	A	A	TAPC
30	F	24	A	A	A	A	P	P	A	A	A	A	P	P	A	A	A	A	A	A	TAPC
32	F	6	A	A	A	A	P	P	A	A	A	P	A	A	A	A	A	A	A	A	TAPC
38	M	1	A	A	A	A	P	A	A	A	P	A	P	A	A	A	A	A	A	A	TAPC
26	F	15	A	A	A	A	A	P	A	A	P	P	A	A	A	A	A	A	A	A	TAPC
35	F	12	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	A	TAPC
34	M	36	A	A	A	A	P	P	A	A	A	A	A	A	A	A	A	A	A	A	TAPC
28	M	24	A	A	A	A	A	P	A	A	P	P	A	A	A	A	A	A	A	A	TAPC
40	M	120	A	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	TAPC
45	M	4	P	A	A	A	P	P	A	A	P	P	A	A	A	A	A	A	P	A	TAPC
47	F	8	A	A	A	A	P	P	A	A	P	P	A	A	P	A	A	A	A	A	TAPC
19	F	84	A	A	A	A	A	P	A	A	P	P	A	A	A	A	A	A	A	A	TAPC
38	F	60	A	A	A	A	P	P	A	A	P	A	P	A	A	A	A	A	A	A	TAPC
53	F	48	A	A	A	A	A	P	A	A	P	P	A	A	A	A	A	A	A	A	TAPC
46	M	36	A	A	A	A	A	P	A	A	P	P	A	A	A	A	A	A	A	A	TAPC
34	F	36	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	A	TAPC
56	M	12	P	A	A	A	P	P	A	A	P	A	A	P	A	A	A	A	A	A	TAPC

ID	SX	IQ	Z8	PS	D5	D9	DF	D8	DD	EM	EQ	CE	D6	PA	TO	SF	S9	DI	NI	OU	D
40	M	36	A	A	A	A	A	P	A	A	P	P	A	A	A	A	A	A	A	A	TAPC
39	M	2	A	A	A	A	P	P	A	A	A	A	A	A	A	A	A	A	A	A	TAPC
36	F	9	A	P	A	A	P	P	A	A	P	P	A	A	A	A	A	A	A	A	TAPC
	F	18	P	P	A	A	A	P	A	A	A	A	A	A	P	A	A	A	A	A	TAPC
40	F	24	P	A	A	A	A	P	A	A	P	A	A	P	A	A	A	A	A	A	TAPC
66	F	36	P	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	TAPC
62	M	42	P	A	A	A	A	P	A	A	P	A	A	A	A	A	A	A	A	A	TAPC
53	M	72	P	A	A	A	A	P	A	A	A	A	A	P	A	A	A	A	A	A	TAPC
		24	P	A	A	A	A	P	A	A	P	A	A	A	A	A	A	A	A	A	TAPC
56	F	120	P	A	A	A	A	P	A	A	P	P	A	A	A	A	A	A	A	A	TAPC
59	F	12	P	A	A	A	A	P	A	A	A	A	A	P	A	A	A	A	P	A	TAPC
69	M		P	A	A	A	A	P	A	A	P	A	A	P	A	A	A	A	A	A	TAPC
38	M	5	P	A	A	P	A	P	A	A	A	A	A	P	A	A	A	A	A	A	TAPC
35	F	30	P	A	A	A	A	P	A	A	P	A	A	A	A	A	A	A	P	A	TAPC
49	M	30	A	A	A	A	A	P	A	A	A	A	A	P	A	A	A	A	A	A	TAPC
35	M	18	A	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	TAPC
73	F	216	A	A	A	A	A	P	A	A	A	A	A	P	P	A	A	A	A	A	TAPC
51	F	30	A	A	A	A	A	P	A	A	P	A	A	P	A	A	A	A	A	A	TAPC
43	M	24	P	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	P	A	TAPC
45	M	120	P	A	A	A	A	P	A	A	P	A	A	A	P	A	A	A	A	A	TAPC
47	F		A	A	A	A	A	P	A	A	A	A	P	P	A	A	A	A	A	A	TAPC
68	F	96	A	A	A	A	A	P	A	A	A	A	A	A	P	A	A	A	A	A	TAPC
53	F	18	P	A	A	A	A	P	A	A	P	A	A	P	P	A	A	A	A	A	TAPC
51	M	12	P	A	A	A	A	P	A	A	P	A	A	A	P	A	A	A	A	A	TAPC
54	M	24	P	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	TAPC
51	F	12	P	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	TAPC
60	F	36	A	A	A	A	A	P	A	A	A	A	A	P	P	A	A	A	A	A	TAPC
34	M		A	A	A	A	A	P	A	A	P	P	A	A	A	A	A	A	A	A	TAPC
26	F	6	A	A	A	A	A	P	A	A	A	P	A	A	P	A	A	A	P	A	TAPC
29	F	8	P	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	TAPC
66	F	72	P	A	A	A	A	P	A	A	A	A	A	A	P	A	A	A	A	A	TAPC
45	M		P	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	TAPC
46	M	46	P	A	A	A	A	P	A	A	A	A	A	A	P	A	A	A	A	A	TAPC
51	F	108	P	A	A	A	A	P	A	A	A	A	A	P	P	A	A	A	A	A	TAPC
42	M	120	A	A	A	A	A	P	A	A	A	A	A	P	P	A	A	A	A	A	TAPC
39	F	30	A	A	A	A	A	P	A	A	A	P	P	A	P	A	A	A	A	A	TAPC
50	M	12	P	A	A	A	P	P	A	A	P	A	A	A	P	A	A	A	A	A	TAPC
51	M	120	P	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	TAPC
37	M	36	A	A	A	A	A	A	A	A	A	A	A	P	A	A	A	A	A	A	TAPC
38	F	11	P	A	A	A	A	P	A	A	P	A	A	P	P	A	A	A	A	A	TAPC
25	F	12	A	A	A	A	A	P	A	A	A	A	A	P	A	A	A	A	A	A	TAPC
		84	A	A	A	A	A	P	A	A	A	A	A	P	A	A	A	A	A	A	TAPC
21	M	48	P	A	A	A	A	P	A	A	P	A	A	P	A	A	A	A	A	A	TAPC
36	M	5	A	A	A	A	A	P	A	A	A	P	A	P	A	A	A	A	P	A	TAPC
52	F	11	P	A	A	A	A	P	A	A	A	A	A	P	A	A	A	A	A	A	TAPC
64	F		A	A	A	A	A	A	A	A	A	A	A	P	A	A	A	A	P	A	TAPC
36	F	24	P	A	A	A	A	P	A	A	P	A	A	A	P	A	A	A	A	A	TAPC
53	F	12	A	A	P	P	A	P	A	A	A	P	A	P	A	A	A	A	A	A	TAPC
55	M	24	A	A	A	A	A	P	A	A	P	A	A	P	A	A	A	A	P	A	TAPC
60	F	96	P	A	A	A	A	P	A	P	P	A	A	A	P	A	A	A	A	A	TAPC
54	M		A	A	A	A	A	P	A	A	A	P	A	P	P	A	A	A	A	A	TAPC
41	M	9	A	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	TAPC
48	F		P	A	A	A	A	P	A	A	P	A	A	A	A	A	A	A	A	A	TAPC
21	M	12	A	A	A	A	A	P	A	A	A	A	A	P	A	A	A	A	A	A	TAPC
56	M	36	P	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	TAPC

[illegible]

ID	SX	IQ	Z8	PS	D5	D9	DF	D8	DD	EM	EQ	CE	D6	PA	TO	SF	S9	DI	NI	OU	D
35	M	5	P	A	A	A	A	P	A	A	P	A	A	A	A	A	A	A	A	A	TAPC
25	F	24	P	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	TAPC
44	F	9	P	A	A	A	A	P	A	A	A	A	A	A	P	A	A	A	A	A	TAPC
54	F	120	A	A	A	A	A	P	A	A	P	A	A	A	A	A	A	A	A	A	TAPC
63	F	9	A	A	A	A	A	P	A	A	P	A	A	P	A	A	A	A	A	A	TAPC
66	M	9	A	A	A	A	A	P	A	A	A	A	A	A	P	A	A	A	A	A	TAPC
50	F	11	P	A	A	A	A	P	A	A	P	A	A	P	A	A	A	A	A	A	TAPC
32	F	5	A	A	A	A	A	P	A	A	A	A	A	P	A	A	A	A	A	A	TAPC
39	M	7	P	A	A	A	A	P	A	A	P	A	A	A	A	A	A	A	A	A	TAPC
57	F	12	A	A	A	A	A	P	A	A	P	A	A	P	A	A	A	A	A	A	TAPC
51	M	24	P	A	A	A	A	P	A	A	P	A	A	A	A	A	A	A	A	A	TAPC
61	F	48	A	A	A	A	A	P	A	A	P	A	A	P	A	A	A	A	A	A	TAPC
39	F	108	A	A	A	A	A	P	A	A	P	A	A	P	A	A	A	A	A	A	TAPC
49	F	12	A	P	A	A	A	P	A	A	P	P	A	P	A	A	A	A	A	A	TAPC
65	F	12	A	A	A	A	A	P	A	A	P	A	A	P	A	A	A	A	A	A	TAPC
53	F	108	A	A	A	A	A	P	A	A	A	P	A	P	A	A	A	A	A	A	TAPC
26	M	42	A	A	A	A	A	P	A	A	P	P	A	A	A	A	A	A	A	A	TAPC
26	F	18	A	A	A	A	A	P	A	A	A	A	A	P	A	A	A	A	A	A	TAPC
57	F	168	P	A	A	A	A	P	A	A	P	A	A	A	A	A	A	A	A	A	TAPC
34	F	8	P	A	A	A	A	P	A	A	P	A	A	A	A	A	A	A	A	A	TAPC
52	F	24	P	A	A	A	A	P	A	A	P	A	A	A	A	A	A	A	A	A	TAPC
49	M	11	P	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	TAPC
55	F	15	A	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	TAPC
47	M	9	P	A	A	A	A	A	A	A	P	A	A	A	A	A	A	A	A	A	TAPC
53	F	4	P	A	A	A	A	P	A	A	P	P	A	A	A	A	A	A	A	A	TAPC
31	M	24	A	A	A	A	A	P	A	A	A	A	A	P	A	A	A	A	A	A	TAPC
48	F	60	A	A	A	A	A	P	P	A	P	P	A	A	A	A	A	A	A	A	TAPC
65	M	5	P	A	A	A	A	P	A	A	P	A	A	A	A	A	A	A	A	A	TAPC
67	F	120	A	A	A	A	A	P	A	A	P	A	A	A	A	A	A	A	A	A	TAPC
57	M	14	P	A	A	A	A	P	A	A	P	A	A	A	A	A	A	A	A	A	TAPC
61	F	48	P	A	A	A	A	P	A	A	P	A	A	P	A	A	A	A	P	A	TAPC
76	M	120	A	A	A	A	A	P	A	A	P	P	A	P	A	A	A	A	A	A	TAPC
44	F		A	A	A	A	A	A	A	A	A	A	A	P	A	A	A	A	A	A	TAPC
67	M	12	A	A	A	A	A	P	A	A	P	A	A	P	A	A	A	A	A	A	TAPC
69	M	60	A	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	TAPC
65	M	120	A	A	A	A	A	P	A	A	P	A	A	P	A	A	A	A	A	A	TAPC
67	F	60	A	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	TAPC
35	F	120	P	A	A	A	A	P	A	A	P	A	A	A	A	A	A	A	A	A	TAPC
22	M		A	A	A	A	A	P	A	A	A	A	A	P	A	A	A	A	A	A	TAPC
24	F	9	P	A	A	A	A	P	A	A	P	A	A	P	A	A	A	A	A	A	TAPC
52	F	36	P	A	A	A	A	A	A	A	P	A	A	A	A	A	A	A	P	A	TAPC
34	M	96	P	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	TAPC
32	F	24	A	A	A	A	P	P	A	A	P	A	A	P	A	A	A	A	A	A	TAPC
40	M	36	P	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	TAPC
67	F	120	P	A	A	A	A	P	A	A	P	A	A	P	A	A	A	A	A	A	TAPC
61	F	10	P	A	A	A	A	P	A	P	P	A	A	A	A	A	A	A	P	A	TAPC
56	M		A	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	TAPC
62	M	120	P	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	TAPC
32	M	60	A	A	A	A	A	P	A	A	P	P	A	P	A	A	A	A	P	A	TAPC
46	F	4	A	A	A	A	A	P	A	A	P	P	A	A	A	A	A	A	A	A	TAPC
55	F	36	P	A	A	A	A	P	A	A	P	A	A	A	A	A	A	A	A	A	TAPC
64	F	120	P	A	A	A	A	P	A	A	P	A	A	A	A	A	A	A	A	A	TAPC
76	F	240	P	A	A	A	A	P	A	A	P	A	A	A	A	A	A	A	A	A	TAPC
60	M	122	P	A	A	A	A	P	A	A	P	A	A	P	A	A	A	A	A	A	TAPC
55	F	24	P	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	TAPC

ID	SX	IQ	Z8	PS	D5	D9	DF	D8	DD	EM	EQ	CE	D6	PA	TO	SF	S9	DI	NI	OU	D
40	M	12	P	A	A	A	A	P	A	A	A	A	A	P	A	A	A	A	A	A	TAPC
16	F		A	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	TAPC
64	M	120	A	A	A	A	A	P	A	A	P	A	A	A	A	A	A	A	A	A	TAPC
35	F	12	A	A	A	A	A	P	A	A	P	A	A	P	A	A	A	A	A	A	TAPC
47	M	6	P	A	A	A	A	P	A	A	P	A	A	P	A	A	A	A	A	A	TAPC
54	F	18	P	A	A	A	A	P	A	A	P	A	A	P	A	A	A	A	A	A	TAPC
39	M	36	P	A	A	A	A	P	A	A	P	A	A	A	A	A	A	A	A	A	TAPC
56	F	42	P	A	A	A	P	P	A	A	P	P	A	P	A	A	A	A	A	A	TAPC
53	M	42	P	A	A	A	A	P	A	A	P	P	P	P	A	A	A	A	A	A	TAPC
53	F		P	A	A	A	A	P	A	A	P	A	A	A	A	A	A	A	A	A	TAPC
60	F	60	P	A	A	A	A	P	A	A	P	A	A	A	A	A	A	A	P	A	TAPC
51	M	10	A	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	TAPC
32	M	12	P	A	A	A	A	P	A	A	P	A	A	A	A	A	A	A	A	A	TAPC
63	F	12	P	A	A	A	A	P	A	A	P	A	A	P	A	A	A	A	P	A	TAPC
23	F		A	A	A	A	A	P	A	A	P	A	A	P	A	A	A	A	P	A	TAPC
57	M	192	P	A	A	A	A	P	A	A	P	A	A	P	A	A	A	A	A	A	TAPC
52	F	24	P	A	A	A	A	P	A	A	P	A	A	P	A	A	A	A	A	A	TAPC
37	M	24	P	A	A	A	A	P	A	A	A	A	A	P	A	A	A	A	A	A	TAPC
54	F	108	A	A	A	A	A	P	A	A	P	A	A	P	A	A	A	A	P	A	TAPC
9	M	36	A	A	A	A	A	P	A	A	P	A	A	A	A	A	A	A	A	A	TAPC
21	F		A	A	A	A	A	P	A	P	P	P	A	P	A	A	A	A	A	A	TAPC
57	M	120	A	A	A	A	A	P	A	A	P	A	A	P	A	A	A	A	A	A	TAPC
51	F		P	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	TAPC
50	F	132	A	A	A	A	A	P	A	A	P	A	A	P	A	A	A	A	A	A	TAPC
26	M	9	A	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	TAPC
58	F	6	P	A	A	A	A	P	A	A	P	A	A	P	A	A	A	A	A	A	TAPC
30	F	63	A	A	A	A	A	P	A	A	A	A	A	P	A	A	A	A	A	A	TAPC
17	M	60	A	A	A	A	A	P	A	A	A	A	A	P	A	A	A	A	P	A	TAPC
17	M	65	A	A	A	A	A	P	A	A	A	A	A	P	A	A	A	A	P	A	TAPC
66	F	12	P	A	A	A	A	P	A	A	P	A	A	P	A	A	A	A	A	A	TAPC
29	F	16	A	A	A	A	A	P	A	A	P	P	P	P	A	A	A	A	P	A	TAPC
45	F	36	P	A	A	A	A	P	A	A	P	P	A	P	A	A	A	A	A	A	TAPC
	F	24	A	A	A	A	A	P	A	P	P	A	A	P	A	A	A	A	P	A	TAPC
52	F	10	A	A	A	A	A	P	A	A	P	A	A	A	A	A	A	A	A	A	TAPC
57	F	30	A	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	TAPC
75	F	36	A	A	A	A	A	P	A	A	P	P	A	A	A	A	A	A	A	A	TAPC
51	M	12	P	A	A	A	A	P	A	A	A	A	A	P	A	A	A	A	A	A	TAPC
54	F	21	P	A	A	A	A	P	A	A	P	A	A	P	A	A	A	A	P	A	TAPC
44	F		A	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	TAPC
35	F	10	P	A	A	A	A	P	A	A	P	P	A	P	A	A	A	A	P	A	TAPC
56	M	12	A	A	A	A	A	P	A	A	P	A	A	A	A	A	A	A	P	A	TAPC
61	F	120	P	A	A	A	A	P	A	A	P	A	A	P	A	A	A	A	A	A	TAPC
30	M		P	A	A	A	A	A	A	A	A	A	P	A	A	A	A	A	P	A	TAPC
28	M	4	A	A	A	A	A	P	A	A	A	A	A	P	A	A	A	A	A	A	TAPC
49	F	18	P	A	A	A	A	P	A	A	P	A	A	A	A	A	A	A	A	A	TAPC
71	F	9	P	A	A	A	A	P	A	A	P	P	A	P	A	A	A	A	A	A	TAPC
60	M	24	P	A	A	A	A	P	A	A	P	A	A	A	A	A	A	A	A	A	TAPC
59	F	8	P	A	A	A	A	P	A	A	P	A	A	A	A	A	A	A	P	A	TAPC
55	F	240	A	A	A	A	A	P	A	A	P	A	A	A	A	A	A	A	A	A	TAPC
58	M	72	A	A	A	A	A	P	A	A	P	A	A	P	A	A	A	A	A	A	TAPC
57	M	120	A	A	A	A	A	P	A	A	P	A	A	A	A	A	A	A	A	A	TAPC
44	M	120	P	A	A	A	A	P	A	A	P	A	A	A	A	A	A	A	A	A	TAPC
26	M	6	A	A	A	A	A	P	A	A	P	A	A	A	A	A	A	A	A	A	TAPC
34	M	30	P	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	P	A	TAPC
49	M	6	A	A	A	A	A	P	A	A	P	A	A	P	A	A	A	A	A	A	TAPC

ID	SX	IQ	Z8	PS	D5	D9	DF	D8	DD	EM	EQ	CE	D6	PA	TO	SF	S9	DI	NI	OU	D
77	F		P	A	A	A	A	P	A	A	P	A	A	A	P	A	A	A	A	A	DORL
37	M		P	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
44	F	1	P	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
58	F	1	A	A	A	A	A	A	P	A	A	A	A	A	P	A	A	A	A	A	DORL
65	M	180	A	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
61	F		P	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
10	M	48	A	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
38	M	1	A	A	A	A	A	P	A	P	A	A	A	A	P	A	A	A	A	A	DORL
51	M	24	P	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
50	F		A	A	A	A	A	A	A	A	A	P	A	A	P	A	A	A	A	A	DORL
50	F	8	P	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
29	M	1	P	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
83	F	1	P	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
69	M	6	P	A	A	A	A	P	A	A	P	A	A	A	A	A	A	A	A	A	DORL
46	F	12	P	A	A	A	A	P	A	P	A	A	A	A	P	A	A	A	A	A	DORL
56	F		A	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
56	M	18	P	A	A	A	A	A	A	P	P	P	A	A	P	A	A	A	A	A	DORL
80	F	12	A	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
52	M	1	P	A	A	A	A	A	A	A	A	A	A	A	P	A	A	A	A	A	DORL
5	M	24	A	A	A	A	A	P	A	A	A	A	A	A	A	A	A	P	A	A	DORL
78	F	96	P	A	A	A	A	P	A	A	A	A	A	A	P	A	A	A	A	A	DORL
70	F	12	A	A	A	A	A	A	A	A	P	A	A	A	P	A	A	A	A	A	DORL
47	M	120	P	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
31	M	132	P	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
85	F		A	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
39	F	6	P	A	A	A	A	A	A	A	A	A	A	A	P	A	A	A	A	A	DORL
35	F	1	A	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
46	F	12	P	A	A	A	A	A	A	A	A	A	A	A	A	A	A	A	A	A	DORL
24	M	2	A	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
56	F	1	P	A	A	A	A	P	A	P	P	A	A	A	A	A	A	A	A	A	DORL
64	F	12	P	A	A	A	A	A	A	A	P	A	A	A	A	A	A	A	A	A	DORL
59	M	1	A	A	A	A	A	A	A	A	P	A	A	A	P	A	A	P	A	A	DORL
56	F	1	P	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
56	F	60	A	A	A	A	A	A	A	A	P	A	A	A	P	A	A	A	A	A	DORL
6	F	2	A	A	A	A	A	A	A	A	A	A	A	A	P	A	A	A	A	A	DORL
61	F	60	A	A	A	A	A	A	A	A	A	A	A	A	P	A	A	A	A	A	DORL
75	F	2	P	A	A	A	A	P	A	A	A	A	A	A	P	A	A	A	A	A	DORL
45	M	1	A	A	A	A	A	A	A	P	P	A	A	A	P	A	A	A	A	A	DORL
48	F	72	P	A	A	A	A	P	A	P	A	A	A	A	P	A	A	A	A	A	DORL
45	F	1	A	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
66	F	48	P	A	A	A	A	A	A	A	A	A	A	A	A	A	A	A	A	A	DORL
40	M	2	A	A	A	A	A	A	A	A	A	A	A	A	P	A	A	A	A	A	DORL
48	M	12	P	A	A	A	A	A	A	A	A	A	A	A	P	A	A	A	A	A	DORL
29	F	8	P	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
59	F	12	P	A	A	A	A	P	A	A	A	A	A	A	P	A	A	A	A	A	DORL
39	F	5	P	A	A	A	A	P	A	A	A	A	A	A	P	A	A	A	A	A	DORL
17	M	24	P	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
88	F	1	A	A	A	A	A	A	A	A	A	A	A	A	P	A	A	A	A	A	DORL
26	F	1	A	A	A	A	A	A	A	A	P	A	A	A	A	A	A	A	A	A	DORL
47	M	1	P	A	A	A	A	A	A	A	P	A	A	A	P	A	A	A	A	A	DORL
89	M	12	A	A	A	A	A	P	A	A	A	A	A	A	P	A	A	A	A	A	DORL
34	F	3	P	A	A	A	A	P	A	A	A	A	A	A	P	A	A	A	A	A	DORL
36	M	1	A	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
39	F	7	A	A	A	A	A	A	A	A	P	A	A	A	P	A	A	A	A	A	DORL
50	F	3	P	A	A	A	A	A	A	A	P	A	A	A	P	A	A	A	A	A	DORL

ID	SX	IQ	Z8	PS	D5	D9	DF	D8	DD	EM	EQ	CE	D6	PA	TO	SF	S9	DI	NI	OU	D
30	F	1	A	P	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
15	F	48	A	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
44	M	24	P	A	A	A	A	P	A	A	A	A	A	A	P	A	A	A	A	A	DORL
59	M	5	P	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
23	F	1	P	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
40	F	1	A	A	A	A	A	P	A	P	P	A	A	A	A	A	A	A	A	A	DORL
66	M	216	A	A	A	A	A	P	P	A	A	A	A	A	A	A	A	A	A	A	DORL
65	M	2	A	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
50	M	36	A	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
77	F	2	A	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
38	F	3	A	A	A	A	A	A	A	A	P	A	A	A	P	A	A	A	A	A	DORL
55	F	12	A	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
63	F	48	P	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
73	F	12	P	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
43	F	1	A	A	A	A	A	A	A	P	P	A	A	A	P	A	A	A	A	A	DORL
49	F	1	A	A	A	A	A	P	A	A	A	A	A	A	P	A	A	A	A	A	DORL
64	M	1	A	A	A	A	A	P	A	A	A	A	A	P	A	A	A	A	A	A	DORL
85	F	1	A	A	A	A	A	P	A	P	P	A	A	A	P	A	A	A	A	A	DORL
38	M	1	A	A	A	A	A	P	A	A	A	A	A	A	P	A	A	A	A	A	DORL
59	F	180	A	A	A	A	A	A	A	P	A	A	A	A	P	A	A	A	A	A	DORL
23	F	1	A	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
33	F	1	P	A	A	A	A	P	A	A	A	P	A	A	P	A	A	A	A	A	DORL
31	F	24	P	A	A	A	A	P	A	P	P	A	A	A	P	A	A	A	A	A	DORL
37	F	1	A	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
48	F	36	P	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
69	M	48	A	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
41	F	60	P	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
49	F	48	P	A	A	A	A	P	A	P	A	A	A	A	P	A	A	A	A	A	DORL
65	M	8	A	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
25	F	1	P	A	A	A	A	P	A	P	A	A	A	A	P	A	A	A	A	A	DORL
33	F	60	A	A	A	A	A	A	A	P	P	A	A	A	P	A	A	A	A	A	DORL
42	F	1	P	A	A	A	A	A	A	A	A	A	A	A	P	A	A	A	A	A	DORL
72	F	2	P	A	A	A	A	A	A	A	A	A	A	A	P	A	A	A	A	A	DORL
70	F	120	P	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
63	F	168	P	A	A	A	A	P	A	A	A	A	A	A	P	A	A	A	A	A	DORL
32	F	1	P	A	A	A	A	A	A	P	P	A	A	A	P	A	A	A	A	A	DORL
53	M	96	A	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
62	M		A	A	A	A	A	P	A	A	P	A	A	A	P	A	A	A	A	A	DORL
74	F		A	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
38	F	1	P	A	A	A	A	P	A	A	A	A	A	A	P	A	A	A	A	A	DORL
71	F	120	A	A	A	A	A	P	A	P	P	A	A	A	A	A	A	A	A	A	DORL
84	M		A	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
89	F	228	A	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
55	F	1	A	A	A	A	A	A	A	P	P	A	A	A	P	A	A	A	A	A	DORL
67	F	36	P	A	A	A	A	A	A	A	A	A	A	A	P	A	A	A	A	A	DORL
68	F	24	P	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
68	M	19	P	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
56	M	120	A	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
35	F	2	A	A	A	A	A	A	A	P	A	P	A	A	P	A	A	A	A	A	DORL
37	M	1	A	A	A	A	A	A	A	A	A	A	A	A	P	A	A	A	A	A	DORL
28	F	1	P	A	A	A	A	A	A	A	A	A	A	A	P	A	A	A	A	A	DORL
41	F	180	P	P	A	A	A	A	A	A	A	P	A	A	P	A	A	A	A	A	DORL
26	M	12	A	A	A	A	A	A	A	A	A	A	A	A	P	A	A	A	A	A	DORL
45	F	60	A	A	A	A	A	A	A	A	A	P	A	P	P	A	A	A	A	A	DORL
35	M	12	A	A	A	A	A	A	A	A	A	A	A	A	P	A	A	A	A	A	DORL

ID	SX	IQ	Z8	PS	D5	D9	DF	D8	DD	EM	EQ	CE	D6	PA	TO	SF	S9	DI	NI	OU	D
49	F	12	A	A	A	A	A	P	A	A	A	A	A	A	P	A	A	A	A	A	DORL
79	M	1	A	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
84	F	1	A	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
63	F	1	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	A	DORL
38	F	12	A	A	A	A	A	A	A	A	A	A	A	A	P	A	A	A	A	A	DORL
52	F	24	A	A	A	A	A	P	A	A	A	A	A	A	P	A	A	A	A	A	DORL
66	M	120	A	A	A	A	A	P	A	P	A	A	A	A	P	A	A	A	A	A	DORL
32	F		A	A	A	A	A	P	A	A	A	A	A	A	P	A	A	A	A	A	DORL
24	F	2	A	A	A	A	A	A	A	P	A	P	A	A	P	A	A	A	A	A	DORL
13	M	24	A	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
78	M	1	A	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
61	F	4	A	A	A	A	A	A	A	P	A	A	A	A	P	A	A	A	A	A	DORL
25	F	12	A	A	A	A	A	P	A	A	A	A	A	A	P	A	A	A	A	A	DORL
10	F	24	A	A	A	A	A	P	A	A	A	P	A	A	A	A	A	A	A	A	DORL
42	M		P	A	A	A	A	P	A	A	A	A	A	A	P	A	A	A	A	A	DORL
55	M	3	P	A	A	A	A	P	A	P	P	A	A	A	P	A	A	A	A	A	DORL
54	F	1	A	A	A	A	A	A	A	P	A	A	A	A	P	A	A	A	A	A	DORL
31	F	96	P	A	A	A	A	A	A	A	A	A	A	A	P	A	A	A	A	A	DORL
57	F		A	A	A	A	A	P	A	A	A	A	A	A	P	A	A	A	A	A	DORL
57	F		P	A	A	A	A	P	A	A	A	A	A	A	P	A	A	A	A	A	DORL
47	F	36	A	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
50	F	1	P	A	A	A	A	P	A	P	A	A	A	A	P	A	A	A	A	A	DORL
77	M	1	A	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
63	F	204	A	A	A	A	A	P	A	A	A	A	A	A	P	A	A	A	A	A	DORL
29	F	12	A	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
11	F	1	A	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
54	M	12	P	A	A	A	A	P	A	A	A	A	A	A	P	A	A	A	A	A	DORL
72	M	36	P	A	A	A	A	P	A	A	P	A	A	A	P	A	A	A	A	A	DORL
21	M	60	P	A	A	A	A	P	A	A	A	A	A	A	P	A	A	A	A	A	DORL
46	M	3	A	A	A	A	A	A	A	P	A	A	A	A	P	A	A	A	A	A	DORL
65	F	1	P	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
62	M	180	P	A	A	A	A	P	A	A	A	A	A	A	P	A	A	A	A	A	DORL
77	F	4	P	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
53	M	6	P	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
30	F	4	P	A	A	A	A	P	A	P	A	A	A	A	P	A	A	A	A	A	DORL
86	M	120	A	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
34	F	12	P	A	A	A	A	P	A	A	A	P	A	A	P	A	A	A	A	A	DORL
18	F	3	P	A	A	A	A	P	A	A	A	A	A	A	P	A	A	A	A	A	DORL
15	M	36	A	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
53	F	252	P	A	A	A	A	A	A	A	A	A	A	A	A	A	A	A	A	A	DORL
71	F	1	P	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
59	F	360	P	A	A	A	A	P	A	A	P	P	A	A	A	A	A	A	A	A	DORL
32	M	60	A	A	A	A	A	P	A	A	A	A	A	P	A	A	A	A	A	A	DORL
72	M	60	A	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
70	F	120	P	A	A	A	A	P	A	P	A	A	A	A	P	A	A	A	A	A	DORL
69	M	24	A	A	A	A	A	P	A	A	P	A	A	A	A	A	A	A	A	A	DORL
77	M	1	P	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
48	M	15	P	A	A	A	A	A	A	P	A	A	A	A	P	A	A	A	A	A	DORL
20	M	24	P	A	A	A	A	P	A	P	P	P	A	A	P	A	A	A	A	A	DORL
40	F	36	A	A	A	A	A	A	A	P	P	A	A	A	P	A	A	A	A	A	DORL
34	F	24	P	A	A	A	A	P	A	A	P	P	A	A	P	A	A	A	A	A	DORL
39	F	1	A	A	A	A	A	P	A	P	A	A	A	A	P	A	A	A	A	A	DORL
77	M	180	P	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
70	M	96	P	A	A	A	A	P	A	A	A	A	A	A	P	A	A	A	A	A	DORL
26	F	24	P	A	A	A	A	A	A	A	A	A	A	A	A	A	A	A	A	A	DORL

[illegible]

ID	SX	IQ	Z8	PS	D5	D9	DF	D8	DD	EM	EQ	CE	D6	PA	TO	SF	S9	DI	NI	OU	D
80	F	120	P	A	A	A	A	P	A	P	A	A	A	A	P	A	A	A	A	A	DORL
70	M	6	P	A	A	A	A	P	A	A	P	A	A	A	P	A	A	A	A	A	DORL
59	M	10	A	A	A	A	A	A	A	A	P	A	A	A	P	A	A	A	A	A	DORL
72	F	24	P	A	A	A	A	A	A	A	A	A	A	A	P	A	A	A	A	A	DORL
79	F	6	A	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
73	M	36	A	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
47	M	36	P	A	A	A	A	A	A	A	A	A	A	A	P	A	A	A	A	A	DORL
26	F	24	A	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
74	M	1	P	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
47	F	6	P	A	A	A	P	A	A	A	A	A	A	A	P	A	A	A	A	A	DORL
34	F	120	A	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
15	M	1	A	A	A	A	A	A	A	P	P	A	A	A	P	A	A	A	A	A	DORL
80	M	8	P	A	A	A	A	P	A	A	A	A	A	A	P	A	A	A	A	A	DORL
52	F	1	P	A	A	A	A	P	A	A	A	A	A	A	P	A	A	A	A	A	DORL
5	M	1	A	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
60	F	216	A	A	A	A	A	P	A	A	A	A	A	A	P	A	A	A	A	A	DORL
29	F	48	P	A	A	A	A	P	A	A	A	A	A	A	P	A	A	A	A	A	DORL
85	F		P	A	A	A	A	P	A	A	P	A	A	A	P	A	A	A	A	A	DORL
34	M	5	A	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
70	M	12	A	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
36	M		P	A	A	A	A	P	A	P	P	A	A	A	P	A	A	A	A	A	DORL
72	F	12	P	A	A	A	A	P	A	A	P	A	A	A	A	A	A	A	A	A	DORL
56	F	180	P	A	A	A	A	P	A	A	A	A	A	A	P	A	A	A	A	A	DORL
63	M	3	P	A	A	A	A	P	A	P	A	A	A	A	P	A	A	A	A	A	DORL
57	F		P	A	A	A	A	A	A	A	A	A	A	A	A	A	A	A	A	A	DORL
90	M		A	A	A	A	A	P	A	A	A	P	A	A	A	A	A	A	A	A	DORL
73	F	120	P	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
88	F		A	A	A	A	A	P	A	A	A	A	A	A	P	A	A	A	A	A	DORL
7	M	1	A	A	A	A	A	A	A	A	P	A	A	A	A	A	A	A	A	A	DORL
42	F	1	A	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
78	F		P	A	A	A	A	P	A	A	A	A	A	A	P	A	A	A	A	A	DORL
63	F	24	A	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
64	F	1	A	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
67	F	60	P	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
65	F		P	A	A	A	A	P	A	A	A	A	A	A	P	A	A	A	A	A	DORL
32	F	1	A	A	A	A	A	A	A	A	P	A	A	A	P	A	A	A	A	A	DORL
63	F	120	P	A	A	A	A	P	A	A	A	A	A	A	P	A	A	A	A	A	DORL
81	F	6	A	A	A	A	A	A	A	A	A	A	A	A	A	A	A	A	A	A	DORL
45	F	1	A	A	A	A	A	P	A	P	A	A	A	A	P	A	A	A	A	A	DORL
40	F	1	A	A	A	A	A	A	A	A	A	A	A	A	P	A	A	A	A	A	DORL
67	F	300	A	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
40	F	24	P	A	A	A	A	A	A	A	P	P	A	A	P	A	A	A	A	A	DORL
35	F	1	A	A	A	A	A	A	A	A	A	A	A	A	P	A	A	A	A	A	DORL
32	F		A	A	A	A	A	P	A	P	A	P	A	A	P	A	A	A	A	A	DORL
49	F	36	A	A	A	A	A	A	A	P	A	A	A	A	P	A	A	A	A	A	DORL
56	M	48	P	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
79	F		P	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
63	F	24	P	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
58	F	3	P	A	A	A	A	P	A	P	P	A	A	A	P	A	A	A	A	A	DORL
58	M		P	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
65	F	1	P	A	A	A	A	A	A	A	A	P	A	A	P	A	A	A	A	A	DORL
44	F	1	A	A	A	A	A	A	A	A	P	A	A	A	P	A	A	A	A	A	DORL
30	F	36	P	A	A	A	A	P	A	A	A	A	A	A	P	A	A	A	A	A	DORL
57	M	12	A	A	A	A	A	A	A	A	A	A	A	A	P	A	A	A	A	A	DORL
58	M	1	P	A	A	A	A	P	A	P	A	A	A	A	P	A	A	A	A	A	DORL

ID	SX	IQ	Z8	PS	D5	D9	DF	D8	DD	EM	EQ	CE	D6	PA	TO	SF	S9	DI	NI	OU	D
56	F		A	A	A	A	A	P	A	A	A	A	A	A	P	A	A	A	A	A	DORL
78	F	2	A	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
65	F	1	P	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
77	F	60	P	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
37	F	60	A	A	A	A	A	P	A	A	A	P	A	A	P	A	A	A	A	A	DORL
54	F	24	P	A	A	A	A	P	A	A	A	A	A	A	P	A	A	A	A	A	DORL
88	M		A	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
53	F		A	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
38	M	1	A	A	A	A	A	A	A	A	A	A	A	A	P	A	A	A	A	A	DORL
72	M	1	P	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
29	F	18	A	A	A	A	A	A	A	P	A	A	A	A	P	A	A	A	A	A	DORL
14	M	12	A	A	A	A	A	P	A	A	P	A	A	A	P	A	A	A	A	A	DORL
44	M	24	A	A	A	A	A	P	A	A	A	A	A	A	P	A	A	A	A	A	DORL
31	F	2	A	A	A	A	A	P	A	A	A	A	A	A	P	A	A	A	A	A	DORL
59	M	1	P	A	A	A	A	P	A	A	A	A	A	A	P	A	A	A	A	A	DORL
31	M	24	A	A	A	A	A	A	A	A	P	A	A	A	A	A	A	A	A	A	DORL
67	F		P	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
74	M	12	P	A	A	A	A	P	A	A	A	A	A	A	P	A	A	A	A	A	DORL
70	M	24	P	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
73	M	1	P	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
80	F	1	A	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
72	F	36	A	A	A	A	A	P	A	A	A	A	A	A	P	A	A	A	A	A	DORL
61	M		P	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
59	F	120	P	A	A	A	A	P	A	A	A	A	A	A	P	A	A	A	A	A	DORL
63	M	1	P	A	A	A	A	P	A	A	A	P	A	A	P	A	A	A	A	A	DORL
68	F	15	A	A	A	A	A	P	A	A	P	A	A	A	P	A	A	A	A	A	DORL
27	M		P	A	A	A	A	P	A	A	A	A	A	A	P	A	A	A	A	A	DORL
34	F	24	P	A	A	A	A	P	A	P	A	A	A	A	P	A	A	A	A	A	DORL
65	M	240	P	A	A	A	A	P	A	A	A	A	A	A	P	A	A	A	A	A	DORL
37	M	2	P	A	A	A	A	A	A	A	A	A	A	A	A	A	A	A	A	A	DORL
58	M	180	P	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
34	M	60	P	A	A	A	A	P	A	P	A	A	A	A	P	A	A	A	A	A	DORL
51	M	3	P	A	A	A	A	A	A	P	A	A	A	A	P	A	A	A	A	A	DORL
67	F	4	P	A	A	A	A	P	A	A	A	A	A	A	P	A	A	A	A	A	DORL
66	M	1	A	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
81	F	120	P	A	A	A	A	P	A	P	A	A	A	A	P	A	A	A	A	A	DORL
76	F	3	A	A	A	A	A	P	A	P	A	A	A	A	P	A	A	A	A	A	DORL
89	F		A	A	A	A	A	P	A	A	A	A	A	A	P	A	A	A	A	A	DORL
78	F	120	P	A	A	A	A	P	A	A	A	A	A	A	P	A	A	A	A	A	DORL
64	F	228	P	A	A	A	A	P	A	A	A	A	A	A	P	A	A	A	A	A	DORL
59	F	3	P	A	A	A	A	P	A	A	A	A	A	A	P	A	A	A	A	A	DORL
60	F	24	A	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
57	F		P	A	A	A	A	P	A	P	A	P	A	A	P	A	A	A	A	A	DORL
56	F	1	A	A	A	A	A	A	A	P	P	A	A	A	P	A	A	A	A	A	DORL
49	F	2	A	A	A	A	A	A	A	A	A	A	A	A	P	A	A	A	A	A	DORL
73	F	72	P	P	A	A	A	P	A	A	A	A	A	A	P	A	A	A	A	A	DORL
74	F	18	P	A	A	A	A	P	A	A	A	A	A	A	P	A	A	A	A	A	DORL
55	M		P	A	A	A	A	A	A	A	A	A	A	A	A	A	A	A	A	A	DORL
64	F	7	A	A	A	A	A	A	A	P	A	A	A	A	P	A	A	A	A	A	DORL
45	M	48	P	A	A	A	A	A	A	A	A	A	A	A	A	A	A	A	A	A	DORL
66	F	5	A	A	A	A	A	A	A	A	A	A	A	A	P	A	A	A	A	A	DORL
76	F		P	A	A	A	A	P	A	A	A	A	A	A	P	A	A	A	A	A	DORL
28	F	1	A	A	A	A	A	A	A	P	A	A	A	A	P	A	A	A	A	A	DORL
55	F	2	P	A	A	A	A	P	A	A	A	P	A	A	A	A	A	A	A	A	DORL
39	F	2	A	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL

ID	SX	IQ	Z8	PS	D5	D9	DF	D8	DD	EM	EQ	CE	D6	PA	TO	SF	S9	DI	NI	OU	D
79	M	120	A	A	A	A	A	P	A	A	P	A	A	A	P	A	A	A	A	A	DORL
10	F	84	A	A	A	A	A	P	A	A	A	A	A	A	A	A	A	P	A	A	DORL
68	F	2	P	A	A	A	A	P	A	P	A	A	A	A	P	A	A	A	A	A	DORL
62	F		P	A	A	A	A	A	A	P	P	A	A	A	P	A	A	A	A	A	DORL
7	F	77	A	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
67	F	96	P	A	A	A	A	P	A	P	A	P	A	A	P	A	A	A	A	A	DORL
81	M		A	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
56	F	1	P	A	A	A	A	P	A	P	A	A	A	A	P	A	A	A	A	A	DORL
70	F		P	A	A	A	A	P	A	A	A	A	A	A	P	A	A	A	A	A	DORL
40	M		P	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
64	M		A	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
67	F		P	A	A	A	A	A	A	A	P	A	A	A	A	A	A	A	A	A	DORL
79	M	12	A	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
82	M		A	A	A	A	A	A	A	A	A	A	A	A	A	A	A	A	A	A	DORL
74	M	120	A	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
66	M	5	P	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
73	F	1	P	A	A	A	A	P	A	A	A	A	A	A	P	A	A	A	A	A	DORL
79	F	3	A	A	A	A	A	P	A	A	A	P	A	A	P	A	A	A	A	A	DORL
13	F	72	A	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
79	F	60	P	A	A	A	A	P	A	A	A	A	A	A	P	A	A	A	A	A	DORL
62	F	240	A	A	A	A	A	P	A	A	A	A	A	A	P	A	A	A	A	A	DORL
14	F	5	A	A	A	A	A	A	A	P	A	A	A	A	P	A	A	A	A	A	DORL
83	M		A	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
77	M		A	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
49	F	1	A	A	A	A	A	A	A	A	A	A	A	A	P	A	A	A	A	A	DORL
46	F	120	A	A	A	A	A	P	A	A	A	A	A	A	P	A	A	A	A	A	DORL
51	M	120	A	A	A	A	A	P	A	A	A	A	A	A	P	A	A	A	A	A	DORL
77	M	1	P	A	A	A	A	P	A	A	A	A	A	A	P	A	A	A	A	A	DORL
56	F	2	A	A	A	A	A	A	A	P	A	A	A	A	P	A	A	A	A	A	DORL
47	M	120	P	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
31	F	1	A	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
7	F	3	A	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
63	M	1	A	A	A	A	A	A	A	P	P	A	A	A	P	A	A	A	A	A	DORL
42	M	48	P	A	A	A	A	P	A	P	A	A	A	A	P	A	A	A	A	A	DORL
6	F	2	A	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
69	M	588	A	A	A	A	A	A	A	A	A	A	A	A	P	A	A	A	A	A	DORL
75	F	1	P	A	A	A	A	A	A	A	A	A	A	A	P	A	A	A	A	A	DORL
64	M	24	P	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
24	F		A	A	A	A	A	A	A	A	A	A	A	A	A	A	A	A	A	A	DORL
62	F	12	A	A	A	A	A	A	A	P	A	P	A	A	P	A	A	A	A	A	DORL
7	M	48	A	A	A	A	A	A	A	A	A	A	A	A	A	A	A	A	A	A	DORL
26	M	3	A	A	A	A	A	P	A	A	A	A	A	A	P	A	A	A	A	A	DORL
64	F	528	P	A	A	A	A	P	A	A	A	A	A	A	P	A	A	A	A	A	DORL
5	F	1	A	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
40	M	120	A	A	A	A	A	P	A	A	A	A	A	A	P	A	A	A	A	A	DORL
50	M	100	P	A	A	A	A	P	A	P	P	A	A	A	P	A	A	A	A	A	DORL
75	F	1	P	A	A	A	A	P	A	A	P	A	A	A	P	A	A	A	A	A	DORL
14	F	7	A	A	A	A	A	A	A	A	P	P	A	A	P	A	A	A	A	A	DORL
40	F		A	A	A	A	A	P	A	A	A	A	A	A	P	A	A	A	A	A	DORL
84	F	120	A	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
69	F	180	P	A	A	A	A	P	A	A	A	P	A	A	A	A	A	A	A	A	DORL
60	F	120	P	A	A	A	A	A	A	A	P	A	A	A	A	A	A	A	A	A	DORL
67	F	300	P	A	A	A	A	A	A	A	A	A	A	A	A	A	A	A	A	A	DORL
58	M	360	P	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
24	F	10	A	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL

ID	SX	IQ	Z8	PS	D5	D9	DF	D8	DD	EM	EQ	CE	D6	PA	TO	SF	S9	DI	NI	OU	D
15	M	12	A	A	A	A	A	P	A	A	A	A	A	A	P	A	A	A	A	A	DORL
65	F	312	P	A	A	A	A	A	A	P	A	A	A	A	P	A	A	A	A	A	DORL
56	M	2	P	A	A	A	A	A	A	P	A	A	A	A	P	A	A	A	A	A	DORL
87	M	6	A	A	A	A	A	P	A	A	P	A	A	A	P	A	A	A	A	A	DORL
36	F		P	A	A	A	A	P	A	P	P	P	A	A	A	A	A	A	A	A	DORL
83	M	36	A	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
88	F	6	P	A	A	A	A	P	A	A	A	A	A	A	P	A	A	A	A	A	DORL
40	F		A	A	A	A	A	A	A	A	A	A	A	A	P	A	A	A	A	A	DORL
55	F	1	P	A	A	A	A	A	A	A	A	A	A	A	A	A	A	A	A	A	DORL
50	F	240	A	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
60	M		P	A	A	A	A	A	A	A	A	A	A	A	A	A	A	A	A	A	DORL
53	F	156	P	A	A	A	A	A	A	P	A	P	A	A	P	A	A	A	A	A	DORL
42	F	127	A	A	A	A	A	A	A	A	A	A	A	A	P	A	A	A	A	A	DORL
65	M	12	P	A	A	A	A	A	A	A	A	A	A	A	A	A	A	A	A	A	DORL
80	F	3	P	A	A	A	A	P	A	A	A	A	A	A	P	A	A	A	A	A	DORL
52	F	3	A	A	A	A	A	A	A	P	A	A	A	A	P	A	A	A	A	A	DORL
54	M	2	A	A	A	A	A	A	A	A	A	A	A	A	P	A	A	A	A	A	DORL
53	F	1	P	A	A	A	A	A	A	A	A	A	A	A	P	A	A	A	A	A	DORL
62	F	2	A	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
24	F	26	P	A	A	A	A	P	A	A	A	P	A	A	A	A	A	A	A	A	DORL
41	M	40	P	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
71	M	60	A	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
60	M	480	A	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
63	F	120	P	A	A	A	A	P	A	A	A	A	A	A	P	A	A	A	A	A	DORL
81	F	6	A	A	A	A	A	A	A	A	A	A	A	A	A	A	A	A	A	A	DORL
45	F	1	A	A	A	A	A	P	A	P	A	A	A	A	P	A	A	A	A	A	DORL
40	F	1	A	A	A	A	A	A	A	A	A	A	A	A	P	A	A	A	A	A	DORL
67	F	300	A	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
40	F	24	P	A	A	A	A	A	A	A	P	P	A	A	P	A	A	A	A	A	DORL
35	F	1	A	A	A	A	A	A	A	A	A	A	A	A	P	A	A	A	A	A	DORL
32	F		A	A	A	A	A	P	A	P	A	P	A	A	P	A	A	A	A	A	DORL
49	F	36	A	A	A	A	A	A	A	P	A	A	A	A	P	A	A	A	A	A	DORL
56	M	48	P	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
79	F		P	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
63	F	24	P	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
58	F	3	P	A	A	A	A	P	A	P	P	A	A	A	P	A	A	A	A	A	DORL
58	M		P	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
65	F	1	P	A	A	A	A	A	A	A	A	P	A	A	P	A	A	A	A	A	DORL
44	F	1	A	A	A	A	A	A	A	A	P	A	A	A	P	A	A	A	A	A	DORL
30	F	36	P	A	A	A	A	P	A	A	A	A	A	A	P	A	A	A	A	A	DORL
57	M	12	A	A	A	A	A	A	A	A	A	A	A	A	P	A	A	A	A	A	DORL
58	M	1	P	A	A	A	A	P	A	P	A	A	A	A	P	A	A	A	A	A	DORL
56	F		A	A	A	A	A	P	A	A	A	A	A	A	P	A	A	A	A	A	DORL
78	F	2	A	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
65	F	1	P	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
77	F	60	P	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
37	F	60	A	A	A	A	A	P	A	A	A	P	A	A	P	A	A	A	A	A	DORL
54	F	24	P	A	A	A	A	P	A	A	A	A	A	A	P	A	A	A	A	A	DORL
88	M		A	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
53	F		A	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
38	M	1	A	A	A	A	A	A	A	A	A	A	A	A	P	A	A	A	A	A	DORL
72	M	1	P	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
29	F	18	A	A	A	A	A	A	A	P	A	A	A	A	P	A	A	A	A	A	DORL
14	M	12	A	A	A	A	A	P	A	A	P	A	A	A	P	A	A	A	A	A	DORL
44	M	24	A	A	A	A	A	P	A	A	A	A	A	A	P	A	A	A	A	A	DORL

ID	SX	IQ	Z8	PS	D5	D9	DF	D8	DD	EM	EQ	CE	D6	PA	TO	SF	S9	DI	NI	OU	D
31	F	2	A	A	A	A	A	P	A	A	A	A	A	A	P	A	A	A	A	A	DORL
68	F	12	A	A	A	A	A	A	A	P	A	P	A	A	P	A	A	A	A	A	DORL
25	M	36	A	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
76	F	2	A	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
67	M	120	P	A	A	A	A	A	A	A	A	A	A	A	A	A	A	A	A	A	DORL
61	M	1	A	A	A	A	A	P	A	A	A	A	A	A	P	A	A	A	A	A	DORL
60	F	12	P	A	A	A	A	A	A	A	A	A	A	A	A	A	A	A	A	A	DORL
70	M	6	A	A	A	A	A	A	A	A	P	A	A	A	P	A	A	A	A	A	DORL
39	F	1	P	A	A	A	A	A	A	P	A	A	A	A	P	A	A	A	A	A	DORL
56	M	24	P	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
42	F	12	A	A	A	A	A	P	A	A	A	A	A	A	P	A	A	A	A	A	DORL
60	M	33	P	A	A	A	A	A	A	A	A	A	A	A	A	A	A	A	A	A	DORL
77	M	60	A	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
56	F	12	P	A	A	A	A	P	A	A	A	A	A	A	P	A	A	A	A	A	DORL
18	F	41	P	A	A	A	A	P	A	P	P	P	A	A	P	A	A	A	A	A	DORL
58	F	12	P	A	A	A	A	P	A	P	A	A	A	A	P	A	A	A	A	A	DORL
31	F	24	A	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
28	F	36	A	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
74	F	12	A	A	A	A	A	P	A	A	A	A	A	A	P	A	A	A	A	A	DORL
24	M	4	A	A	A	A	A	P	A	A	A	A	A	A	P	A	A	A	A	A	DORL
62	M	1	A	A	A	A	A	A	A	P	A	A	A	A	P	A	A	A	A	A	DORL
63	M	1	P	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
46	F	1	P	A	A	A	A	A	A	P	A	A	A	A	P	A	A	A	A	A	DORL
36	M	1	A	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
47	F	1	A	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
27	F	2	A	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
40	F	1	A	A	A	A	A	A	A	A	P	A	A	A	P	A	A	A	A	A	DORL
48	F	1	A	A	A	A	A	A	A	A	A	A	A	A	P	A	A	A	A	A	DORL
68	F		P	A	A	A	A	P	A	A	A	P	A	A	P	A	A	A	A	A	DORL
7	F	1	A	A	A	A	A	A	A	A	A	A	A	A	A	A	A	A	A	A	DORL
34	F	72	A	A	A	A	A	A	A	A	A	A	A	A	A	A	A	A	A	A	DORL
55	M		P	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
85	F	2	A	A	A	A	A	A	A	A	A	A	A	A	P	A	A	A	A	A	DORL
67	M	120	P	A	A	A	A	P	A	A	A	A	A	A	A	A	A	A	A	A	DORL
45	M	72	P	A	A	A	A	P	A	A	P	A	A	A	A	A	A	A	A	A	DORL

ANEXO B

Discriminação Histológica

ANEXO B

No desenvolver da presente Dissertação vislumbrou-se a possibilidade da execução de um segundo experimento. Nesse experimento obteve-se um modelo (classificador) capaz de discriminar o tipo histológico entre epidermoide (EPID) e neurinoma do acústico (NEUR). Foram usados 275 casos, sendo que 58 representavam tumores EPID e 217 NEUR. A idade variou de 9 a 76 anos, com média para esses casos de 46,33 anos.

Foram mantidos os mesmos sinais e sintomas descritivos dos casos. O segundo modelo apresenta uma estrutura útil na tarefa de diferenciar entre dois tipos histopatológicos de tumores do APC: Epidermóides e Neurinomas. Os resultados mostram ser possível, antes mesmo da análise histopatológica e olhando-se apenas para sinais e sintomas clínicos não invasivos, a diferenciação entre esses dois tipos de tumor.

Esse modelo indica que o comprometimento do oitavo nervo craniano, traduzido pelos sinais zumbido, acúfenos ou tinnitus, leva ao diagnóstico histológico de neurinoma (NEUR), com precisão de 97,69%, quando comparado apenas com o tipo epidermoide (EPID).

A Figura 9 mostra a árvore de decisão obtida por CART para os casos de Epidermóides e Neurinomas. Nela pode-se notar que dos 21 sinais e sintomas coletados, apenas 3 foram usados pelo modelo (Z8, PA e DF).




Figura 9. Árvore de decisão fornecida por CART para o modelo de discriminação EPID x NEUR. Z8 representa zumbido, acúfenos e tinitus, PA é a paresia dos nervos facial e/ou glossofaríngeo e DF é o comprometimento da sensibilidade da face. Rotulando cada ramo temos A=Ausência e P=Presença. Cada nó terminal é numerado 1-4.

A variável mais importante é a Z8, que está na raiz da árvore e representa a presença (P) ou ausência (A) de zumbido, acúfenos ou tinitus. O modelo obtido indica que a presença de Z8 leva a um diagnóstico de NEUR. Por outro lado, quando distúrbio relacionado ao oitavo nervo (Z8)

estiver ausente, deve-se verificar o valor da variável PA, no caso onde PA é também ausente, o diagnóstico indicado é EPID. Caso PA esteja presente a terceira variável deve ser verificada, trata-se de DF. Esta sendo ausente, indica-se NEUR, caso contrário EPID. A relevância de cada um desses diagnósticos indicados pelo modelo, é apresentada adiante, na Figura 10.

A Tabela 4 apresenta as frequências de acerto e erro do modelo. A acurácia total do modelo, testado face à validação cruzada, é de 83% de diagnósticos corretos. A sensibilidade do modelo face ao diagnóstico de NEUR isoladamente, é de 82%. A porcentagem de falsos positivos (FP) é de 3,27%, enquanto que os falsos negativos (FN) perfazem 14%.

Tabela 4. Matriz de frequências obtida na avaliação da árvore de decisão da Figura 9

	RNEUR	REPID
HNEUR	177	9
HEPID	40	49

A Figura 10 apresenta a relevância de cada um dos nós terminais da árvore de decisão. Entre os quatro nós terminais apenas o nó 3 (Epid) não é relevante. Porém, todos os outros nós indicam diagnósticos relevantes, notadamente os nós 2 e 4 (NEUR), daí a alta sensibilidade, ponto forte desse modelo. O nó terminal 2 representa 73 casos que incidem sobre o mesmo, desses 64 (87,67%) são casos de NEUR e 9 (12,33%) de EPID. Em consequência, casos que apresentam ausência de distúrbios Z8, presença de paresia (PA) e ausência de distúrbio de sensibilidade na face

(DF), são diagnosticados pelo modelo como NEUR. Incidem no nó terminal 4, 130 casos, desses, 127 (97,69%) são casos de NEUR e apenas 3 (2,31%) de EPID. Portanto, quando existir presença de Z8, o modelo diagnosticará como NEUR.




Figura 10. Relevância dos nós terminais na árvore representada na Figura 9.